

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Marko Topalušić

Zagreb, 2014.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Biserka Runje, dipl. ing.

Student:

Marko Topalušić

Zagreb, 2014.

IZJAVA

Izjavljujem da sam diplomski rad na temu “ŠEST SIGMA METODOLOGIJA I PLANIRANJE POKUSA” izradio potpuno samostalno uz pomoć navedene literature i znanja stečenog tijekom studija. Pomoć pri odabiru stručne literature i oblikovanju završnog rada pružila mi je dr. sc. Biserka Runje.

Marko Topalušić

ZAHVALA

Zahvaljujem se svojoj mentorici dr. sc. Biserki Runje koja mi je svojim znanjem, sugestijama, pomoći i strpljenju omogućila da što uspješnije privedem svoj diplomski rad kraju.

Također bih se zahvalio svojoj obitelji, djevojci i prijateljima koji su mi bili podrška i pomoć tijekom izrade ovog rada.

SADRŽAJ

1. UVOD.....	1
2. ŠEST SIGMA.....	2
2.1. Šest sigma - Općenito	2
2.2. Šest sigma – Metodologija	6
2.3. Šest sigma – Metrika	10
2.4. Šest sigma alati.....	11
3. PLANIRANJE POKUSA	14
3.1. Šest sigma i planiranje pokusa	14
3.2. Općenito – planiranje pokusa	14
3.3. Temeljna načela	16
3.4. Smjernice za planiranje pokusa.....	17
4. POTPUNI PLAN POKUSA (FAKTORSKI PLAN POKUSA)	19
5. DJELOMIČNI PLAN POKUSA	27
5.1. Rezolucija djelomičnih planova pokusa.....	27
5.2. Konstruiranje djelomičnog plana pokusa	29
6. TAGUCHIJEVA METODA	32
6.1. Primjena Taguchija u planiranju pokusa.....	37
7. METODA ODZIVNE POVRŠINE	39
8. EKSPERIMENTALNI DIO	42
8.1. Primjer metode odzivne površine	42
8.2. Primjer djelomičnog plana pokusa	54
9. ZAKLJUČAK.....	65
10. POPIS SLIKA.....	66
11. POPIS TABLICA	67
12. LITERATURA	68

SAŽETAK

Tema ovog diplomskog rada je "Šest sigma metodologija i planiranje pokusa". U radu je predstavljena Šest sigma metodologija kao način upravljanja proizvodnjom. Opisane su osnovne postavke Šest sigma metodologije s posebnim osvrtom na Six Sigma metriku. Također su navedene metode i alati koje Šest sigma metodologija koristi u cilju stalnog poboljšavanja kvalitete. U sklopu ovog rada, osim Šest sigma metodologije, razrađeno je i planiranje pokusa koje u sklopu Šest sigme služi kao alat pomoću kojeg se u svakom procesu može poboljšati razina kvalitete.

U prvom dijelu rada nalaze se informacije o povijesti i razvoju Šest sigma metodologije, obrađena je statistička definicija Šest sigme te su pojašnjeni osnovni pojmovi vezani za Šest sigma metodologiju, metriku i alate koji se koriste.

Drugi dio rada govori o planiranju pokusa te su opisana temeljna načela i smjernice za planiranje pokusa. Poseban naglasak stavljen je na metode koje se odnose na fazu "Improve" DMAIC sheme, odnosno Planiranje pokusa.

U trećem dijelu izdvojene su glavne vrste planova pokusa te je objašnjena njihova metodologija. Uz sistematizaciju najčešćih statističkih metoda napravljen je kratak opis te način i svrha njihove primjene. Opisani su potpuni i djelomični faktorski planovi pokusa, zatim metoda odzivne površine i Taguchijeva metoda planiranja pokusa pogodna za primjenu u proizvodnji i kontroli kvalitete.

Nakon što su u prethodnim poglavljima pobliže objašnjeni navedeni planova pokusa, u četvrtom dijelu prikazan je eksperimentalni dio rada koji čine dva konkretna primjera planiranja pokusa s detaljnom analizom izrađenom pomoću softverskog programa DesignExpert.

1. UVOD

Načela Šest sigma metodologije uključuju primjenu naprednih statističkih metoda i alata koji su potrebni za postizanje efikasnosti procesa. U cilju smanjenja troškova i postizanja stalnog poboljšavanja procesa, razvijene su brojne metode i alati upravljanja kvalitetom temeljene na statističkim postavkama. Metode planiranja pokusa imaju veliku primjenu u raznim disciplinama. Upotreba statističkih metoda planiranja pokusa može znatno povećati efikasnost samog procesa eksperimentiranja i dovesti do boljih i pouzdanijih zaključaka. Planiranje pokusa možemo shvatiti kao dio znanstvenog procesa i kao jedan od načina na koji možemo saznati kako sustavi ili procesi rade. Općenito, učimo kroz niz aktivnosti u kojima stvaramo pretpostavke o procesu, obavljamo pokuse kako bi generirali podatke iz procesa, a zatim koristimo informacije iz pokusa kako bi napravili nove pretpostavke koje će nas dovesti do novih pokusa i tako dalje.

Prva primjena statistike u industriji zabilježena je početkom 20.st. u Dublinu kada je W.S. Gosset primjenom znanstvenog pristupa riješio određene tehnološke probleme u kontroli kvalitete proizvodnje piva i tako postao jedan od prvih i najznačajnijih industrijskih statističara. Njegova metoda za promatranje malih uzoraka je kasnije primijenjena na mnoga područja ljudskih aktivnosti, a vrlo rijetko je pronašla primjenu u industriji sve do 1920. godine kada je proširuje Ronald A. Fisher. On je bio inovator u primjeni statističkih metoda u planiranju pokusa. Razvio je i prvi upotrijebio analizu varijanci kao primarnu metodu statističke analize u planiranju pokusa. Prve industrijske primjene planiranja pokusa su se počele pojavljivati 1930-ih godina u tekstilnoj i vunenoj industriji Velike Britanije. Nakon Drugog svjetskog rata, metode planiranje pokusa su uvedene u kemijsku i procesnu industriju u SAD-u i Zapadnoj Europi, a već mnogo godina ih s velikim uspjehom koristi i elektronička industrija. U posljednjih nekoliko godina se probudio ponovni interes za planiranje pokusa u SAD-u jer su mnoge industrije otkrile da njihova prekomorska konkurencija već dugu niz godina koristi metode planiranja pokusa te da je to vrlo bitan faktor u njihovom uspjehu. Uspješna integracija planiranja pokusa u inženjersku struku je ključni faktor u budućoj konkurentnosti industrije u SAD-u.

2. ŠEST SIGMA

2.1. Šest sigma - Općenito

Statistička metoda Šest sigma razvijena je sredinom osamdesetih godina 20. stoljeća u kompaniji Motorola. Bill Smith, inženjer u Motoroli, odabrao je naziv Six sigma za metodu kojom bi smanjio broj grešaka u proizvodnji budući da dotadašnje metode nisu davale dovoljno dobre rezultate, kako bi mogli konkurirati naglo rastućoj japanskoj industriji. Dr. Mikel Harry osnovao je tim, sa Smithom kao članom, i izradio koncept unaprjeđenja kvalitete na osnovi 3,4 grešaka na milijun pokušaja. Taj organizacijski koncept postao je poznat kao Šest sigma te se bazirao na četiri osnovna koraka:

- Mjerenje;
- Analiza;
- Unaprjeđenje;
- Kontrola.


Brojka šest u nazivu odnosi se na razinu šest sigma kvalitete kojima svako poduzeće teži. Sigma je grčki simbol koji označava standardnu devijaciju. Cilj Šest sigme je svesti škart na najmanju moguću razinu, smanjiti troškove i vrijeme proizvodnje te povećati produktivnost i poboljšati poslovne rezultate. Osnovna mjerna jedinica Šest sigme je DPMO (*Defects per million opportunities*), što u prijevodu znači broj grešaka na milijun događaja.

Širina zahtjeva U - L	Vjerojatnost %	DPMO	Pomak od 1,5σ Vjerojatnost,% DPMO	
± 1σ	68,27	317 300	30,23	697 700
± 2σ	95,45	45 500	69,13	308 700
± 3σ	99,73	2 700	93,32	66 810
± 4σ	99,9937	63	99,3790	6 210
± 5σ	99,999 943	0,57	99,976 70	233
± 6σ	99,999 999 8	0,002	99,999 660	3.4

Slika 1. DPMO

Na slici 1. prikazana je tablica s vrijednostima DPMO u korelaciji sa širinom zahtjeva. Kako bi se to postiglo, koriste se razne statističke tehnike i metodologije bazirane na mjerljivim podacima kojima je cilj kontrola kvalitete.

Metodologijom Šest sigma poboljšavamo procese koji su opisani pomoću normalne razdiobe (Slika 2.) koju je definirao Carl Friedrich Gauss pa se još naziva i Gaussova krivulja. Ona ima oblik zvona, te je simetrična oko osi y, a os x joj je asimptota koja seže od $-\infty$ do $+\infty$. Ova je krivulja potpuno neovisna od granica dopuštenih odstupanja (LSL I USL), a njen oblik isključivo ovisi o procesu, opremi, osoblju i ostalim čimbenicima.




Slika 2. Normalna razdioba

Normalna razdioba pripada kontinuiranoj razdiobi u kojoj kontinuirana slučajna varijabla može poprimiti bilo koju vrijednost u određenom intervalu. Slučajna varijabla koja je distribuirana po normalnoj razdiobi je veličina na koju djeluje više nezavisnih slučajnih faktora.

Normalna razdioba se gleda statistički kao površina koja je omeđena sa $\pm 6\sigma$ za koju odgovara vjerojatnost od 99,9999998% što odgovara pojavi dvije greške na milijardu mogućnosti. Motorola je ustvrdio da svaki proces varira tokom vremena i to su nazvali dugoročnom dinamikom srednje varijacije. Zbog toga se u teoriji Šest sigma iskustveno uzima pomak procesa od središta za $1,5\sigma$, kao najgori slučaj

pomaka, iz čega i proizlazi da broj grešaka iznosi 3,4 po milijunu. U metodologiji Šest sigma upravo se govori o slučaju s pomakom jer su to praktične vrijednosti diskretnih iznosa grešaka na milijun mogućnosti (DPMO).

Slika 3. nam prikazuje normalnu razdiobu za Šest sigma bez pomaka i sa njim. Crveni dio predstavlja DPMO nakon pomaka. On se nalazi izvan granica dopuštenih odstupanja. USL predstavlja gornju, a LSL donju granicu. U ovakvom slučaju dolazi do 3,4 DPMO iznad gornje granice, a dio ispod donje je zanemariv. Proces bez pomaka ima 0,001 DPMO sa svake strane granice (što iznosi dvije greške po milijardi).



Slika 3. Pomak procesa

Svaki stvarni proces se tijekom vremena pomiče uz pretpostavku približno istog rasipanja. Ako se proces nadzire, taj pomak može biti kontroliran te sukladno zahtjevima kupca i kvaliteti procesa pomak može biti značajno manji, ali i veći od $1,5\sigma$ uz $DPMO=3,4$.

Funkcija vjerojatnosti ima oblik:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{\frac{-(x-\mu)^2}{2\sigma^2}}$$

Varijanca normalne razdiobe iznosi:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2$$

Gdje je:

n – neovisna opažanja (broj ponovljenih mjerenja)

μ – očekivanje (istinita vrijednost)

x_i – slučajna varijabla (i -ti rezultat mjerenja)

Iz varijance možemo izračunati standardno odstupanje σ (sigma):

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$$

2.2. Šest sigma – Metodologija

Osnovna svrha Šest sigma metodologije je implementirati strategije temeljene na mjerenjima koje su usredotočene na poboljšavanje procesa i smanjenje varijacija.

Postoje dvije osnovne metode poboljšanja Šest sigma:

- DMAIC (Define – Measure – Analyze – Improve – Control);
- DMADV (Define – Measure – Analyze – Design – Verify);

DMAIC (Define – Measure – Analyze – Improve – Control)


Metoda poboljšanja DMAIC (Slika 3.) daje okvir za pojedinačne projekte unaprjeđenja procesa. Sastoji se od neprekidnog definiranja problema u procesu, njihovog mjerenja, analize, unaprjeđenja i kontrole procesa, proizvoda. Zasniva se na realnim problemima, njihovom definiranju, korištenju različitih organizacijskih alata i tehnika kod svih stupnjeva/koraka Šest sigme, kontinuiranog i sistematičnog unaprjeđenja kroz dugo razdoblje i djelovanja kao inicijator mnogih promjena unutar organizacije. DMAIC metoda može unaprijediti proces i za 70 % i smanjiti broj grešaka za 30 % do 70 %. Ista može biti ponavljana nekoliko puta na istom procesu prije nego dođe do stanja kad je to više nemoguće.

DMAIC metoda poboljšavanja procesa se sastoji od pet koraka:

1. Definiranje (engl. define) - Prvo je potrebno definirati sam projekt. U sklopu tog koraka je potrebno definirati cilj i svrhu projekta te prikupiti popratne informacije o procesu kao i one o potrebama i korisničkim specifikacijama. Izlazni rezultati koraka definiranja obuhvaćaju sam iskaz namjeravanog unaprjeđenja procesa, način njegova mjerenja, visoku razinu prikaza procesa i prikaz želja korisnika na kvalitativni način.
2. Mjerenje (engl. measure) - Podrazumijeva se mjerenje postojećeg stanja. Ovdje se najprije zajednički prikupe informacije o postojećoj situaciji kako bi se na temelju njih dobile jasnije predodžbe gdje treba preusmjeriti svoje aktivnosti. Izlazni rezultati koraka mjerenja obuhvaćaju podatke koji najbolje

opisuju lociranje problema, stupanj pojavnosti problema, osnovne podatke koji opisuju na koji način proces funkcionira te koliko kvalitetno ispunjava korisničke potrebe.

3. Analiziranje (engl. analyze) - Podrazumijeva se analiziranje uzroka. Najprije se identificiraju glavni uzroci smetnji da bi se, nakon toga, to i potvrdilo podacima. Izlazni rezultati ovog koraka dovode do teorije koju je kasnije moguće empirijski provjeriti i potvrditi.
4. Poboljšanje (engl. improve) - Podrazumijevaju se razna poboljšanja procesa, odnosno njegovih dijelova (podprocesa). Cilj ovog koraka je razviti, testirati i implementirati rješenja kako bi se uočili glavni uzroci poremećaja te, na temelju njih, kreirali određeni planovi poslovanja. Izlazi koraka poboljšanja uključuju planirane i testirane akcije koje se obavljaju tako da se eliminira utjecaj glavnih uzročnika problema.
5. Kontrola (engl. control) - Kontrola samog procesa i izlaznih rezultata. Cilj je zadržati dobit koja je stečena standardizacijom radnih metoda i procesa te prihvaćanje budućih poboljšanja, kao i izrada planova za održavanje tih poboljšanja. Izlazi koraka kontrole uključuju dokumentiranje novih metoda, trening prethodno zaposlenih na novim poslovima, sustav za promatranje i provjeru rezultata novih metoda te kompletnu dokumentaciju o povezanosti učenja, rezultata i kasnijih preporuka korištenih metoda drugim poslovnim subjektima.



Slika 4. DMAIC metoda poboljšavanja procesa

DMADV (Define – Measure – Analyze – Design – Verify)

Druga metoda Šest sigma je DMADV (Slika 5.), a ona se koristi prilikom kreiranja novoga proizvoda ili procesa. Metoda poboljšanja procesa DMADV je najpopularniji sastavni dio alatnog paketa DFSS (Design For Six Sigma). DFSS metoda ima za cilj kreirati proces koji ne stvara greške. Ona sadrži mnogo strože alate za identificiranje kritičnih zahtjeva kupaca koje prevodi u proces i njegovu kontrolu, istražuje konstrukcijska alternativna rješenja, razvija detalje konstrukcijskih rješenja i primjenjuje nova konstrukcijska rješenja. Za razliku od DMAIC metode, postupci ili koraci DFSS-a nisu svugdje isto prepoznati i implementirani. Gotovo svaka tvrtka ima svoju definiciju DFSS-a. U nekim slučajevima tvrtka će primijeniti i prilagoditi DFSS svom poslovanju, industriji i kulturi, dok će u drugim slučajevima jednostavno prihvatiti definiciju koju im nametne konzultantska firma koja posluje s njima. Iz tih razloga, DFSS je više pristup nego metodologija.

Ova metoda se sastoji od sljedećih pet koraka:

1. Definiranje konstrukcijskih ciljeva uzimajući u obzir zahtjeve kupaca te poslovnu strategiju tvrtke.

2. Mjerenje i identifikacija CTQ-a (karakteristike koje su kritične za kvalitetu), proizvodna sposobnost, rizici sposobnost proizvodnog procesa.
3. Analiza i razvoj različitih konstrukcijskih rješenja nakon kojih se rješenja ocjenjuju te se izabire najbolja konstrukcija.
4. Detaljiziranje konstrukcija, optimizacija konstrukcija te planiranje provjere konstrukcija - ova faza može zahtijevati razne simulacije.
5. Provjera konstrukcije, izrada prototipova te realizacija procesa



Slika 5. DMADV metoda poboljšavanja procesa

Osim gore navedene metode (DMADV), danas se koristi velik broj metoda u sklopu DFSS-a:

- DMAIC (define, measure, analyze, improve, implement, control)
- IDOV (identify, design, optimize, validate)
- DCCDI (define, customer concept, design, implement)
- DMEDI (define, measure, explore, develop, implement)
- DMADOV (define, measure, analyze, design, optimize, verify)
- CDOC (conceptualize, design, optimize, control)
- DCDOV (define, concept, design, optimize, verify)

2.3. Šest sigma – Metrika

DPMO (Defects Per Million Opportunities)

DPMO predstavlja glavnu mjeru u sustavu Šest sigma. Definira se kao broj nesuglasnosti na milijun prilika, a govori o broju nesukladnosti u procesu. Pomoću DPMO-a se ocjenjuje, unutar Šest sigma proračuna, kvaliteta nekog proizvodnog procesa ili usluge. Također je moguće uspoređivati različite ili paralelne procese unutar iste tvrtke. Za računanje DPMO-a potrebno je poznavati broj nesukladnosti, broj jedinica u uzorku i broj prilika za nesukladnost po jedinici.

$$DPMO = \frac{1,000,000 \times \text{broj nesukladnosti}}{\text{broj jedinica u uzorku} \times \text{broj prilika po jedinici}}$$

DPMO bi prvenstveno trebalo računati prema podacima dobivenim odazivom krajnjeg korisnika proizvoda ili usluge, a ne, kako se u mnogim tvrtkama računa, samo u proizvodnom procesu ili davanju usluge.

DPU (Defects Per Unit)

DPU je broj nesukladnosti po proizvodu koji pokazuje koliki je udio nesukladnosti, odnosno defekata, u odnosu na broj gotovih proizvoda. To je jednostavan pokazatelj kvalitete proizvoda ili usluge. Za računanje DPU potrebno je poznavati ukupan broj nesukladnosti i ukupan broj proizvedenih jedinica.

$$DPU = \frac{\text{ukupan broj nesukladnosti}}{\text{ukupan broj proizvedenih jedinica}}$$

DPO (Defects Per Opportunity)

DPO predstavlja vrijednost koja nam govori koliko će se jedinica proizvesti u procesu bez ijedne nesukladnosti. Za računanje DPO potrebno je poznavati ukupan broj nesukladnosti i ukupan broj prilika za nesukladnosti.

$$DPO = \frac{\text{ukupan broj nesukladnosti}}{\text{ukupan broj prilika za nesukladnosti}}$$

2.4. Šest sigma alati

Osnovna karakteristika Šest sigma modela je uporaba statističkih alata. Pored uporabe statistike, Šest sigma koristi još veliki broj alata za upravljanje kvalitetom čije korištenje najčešće zavisi o fazi DMAIC metode poboljšavanja procesa. Za svaku fazu karakteristična je uporaba velikog broja statističkih alata.

Najvažniji alati koji se koriste unutar Six sigma su:

- definiranje: Pareto analiza,
- mjerenje: Deskriptivna statistika,
- analiza: FMEA analiza,
- poboljšanje: DOE (design of experiments) i Taguchijeva metoda
- kontrola: Kontrolne karte.

Definiranje (engl. define)

Pareto analiza koristi se, prije svega, za razlučivanje najvažnijih uzroka određenih događaja/problema. U slučaju prikupljanja velikog broja podataka pomaže nam da odvojimo važne i nevažne podatke. Pareto pravilo najjednostavnije se ilustrira kroz jednostavnu 80/20 zakonitost, prema kojoj samo 20 posto uzroka rezultira 80% problema; radi se o pravilu koje se može primijeniti u većini životnih situacija. Zahvaljujući primjeni Pareto principa organizacija se može posvetiti najvažnijim

projektima koji su ujedno i financijski najisplativiji, dok veliko mnoštvo problema koji ne stvaraju velike troškove ili njihova neprovođenje ne utječe značajno na povećanje prihoda se može zanemariti.

Mjerenje (engl. measure)

Deskriptivna statistika koristi se za opisivanje funkcioniranja procesa koristeći pritom najjednostavnije statističke pokazatelje. Koristeći deskriptivnu statistiku saznajemo tri stvari o određenoj distribuciji, a to su: lokacija ili centriranost populacije, raspršenost i oblik distribucije. Najčešće korišteni pokazatelji u okviru deskriptivne statistike su: aritmetička sredina, mod, medijan, raspon, varijanca, standardna devijacija, asimetričnost, itd.

Analiziranje (engl. analyze)

FMEA analiza je sistematična metoda čiji je krajnji cilj identificiranje potencijalnih pogreški s ciljem zaustavljanja njihova nastanka kako bi se minimalizirala vjerojatnost da se kupac susretne sa analiziranim pogreškama.

Poboljšanje (engl. improve)

DOE (Design of experiments) metoda ili planiranje pokusa je statistička tehnika kod koje je moguće istodobno pratiti utjecaj dvije ili više izlaznih varijabli određenog procesa. Svi prethodni modeli orijentirali su se na zasebno proučavanje pojedinih varijabli, dok su ostale držali konstantnima.

Taguchieva metoda: polazište ove metode nalazi se u koncepciji „robusnog dizajna“.

Taguchijev model može se sažeti u dvije osnovne ideje:

- Kvaliteta bi se trebala mjeriti kao odstupanje od zadane ciljne vrijednost, a ne kao uklapanje u zadane granice tolerancije kao što je to primjerice slučaj na kontrolnim kartama.
- Kvalitetu je nemoguće osigurati kroz dorade i inspekciju, nego se ona mora postići već prilikom dizajniranja procesa i proizvoda.

Kontrola (engl. control)

Kontrolne karte: najčešći su alat korišten za održavanje procesa pod statističkom kontrolom. U slučaju da kontrolne karte ukazuju na odstupanje od zadanih granica dolazi do obustavljanja proizvodnje. Da bi ih mogli koristiti moramo proces dovesti pod kontrolu. Kontrolne karte dijele se na dvije osnovne vrste, a to su atributivne i varijabilne kontrolne karte, ovisno o vrsti podataka koji se prikupljaju. Atributivni podaci javljaju se onda kad postoje samo dva moguća ishoda mjerenja npr. dobar-loš, prihvatljiv-neprihvatljiv, visok-nizak, itd., dok su kod varijabilnih kontrolnih karata podaci rezultati raznih mjerenja te se najčešće brojčano iskazuju.

3. PLANIRANJE POKUSA

3.1. Šest sigma i planiranje pokusa

Šest sigma teži povećanju uspješnosti poslovanja tako da razinu greške smanji na minimum i poveća kvalitetu samog proizvodnog procesa. Šest sigma se temelji na provjerenim statističkim metodama i metodama kontrole kvalitete koje su integrirane u fazu pod nazivom DMAIC, a spominje se ranije kao jedna od dvije najpoznatije metode poboljšanja Šest sigme. Standard ovakvog načina upravljanja proizvodnjom je samo 3,4 pogreške na milijun proizvoda što je posljedica povećanja zahtjeva korisnika, odnosno tržišta i povećanja složenosti suvremenih proizvoda i procesa.

Poseban naglasak stavljen je na metode poboljšavanja koje se odnose na fazu "Improve" te "Analyze" DMAIC sheme, odnosno Planiranje i analizu pokusa, a razrađeno je i nekoliko primjera uporabe navedenih metoda.

3.2. Općenito – planiranje pokusa

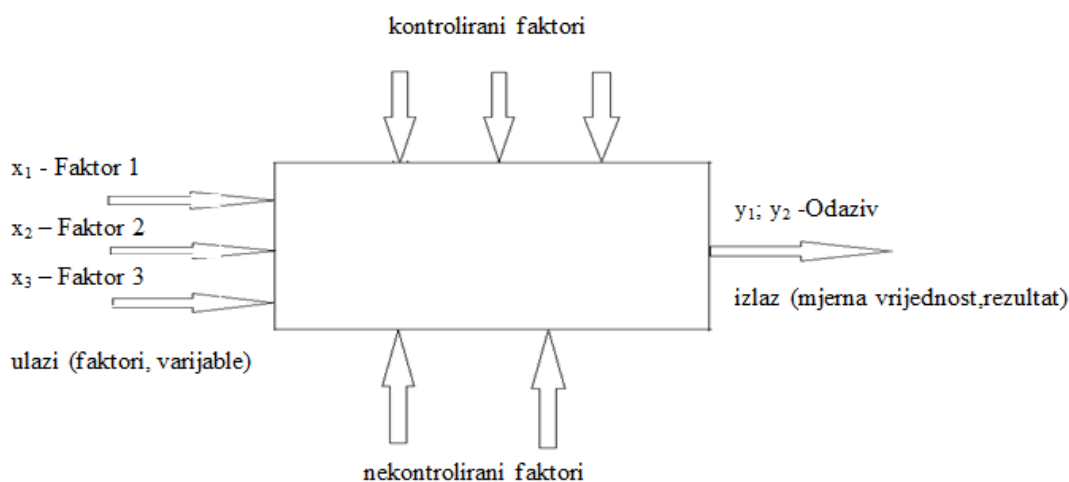
Veliki dio istraživanja u znanosti i inženjerstvu, a pogotovo u industriji je empirijsko. Upotreba statističkih metoda planiranja pokusa može znatno povećati efikasnost samog procesa eksperimentiranja i dovesti do boljih i pouzdanijih zaključaka.

Planiranje pokusa se odnosi na procedure planiranja istraživanja koja se temelje na statističkom ocjenjivanju rezultata ispitivanja kako bi se, s određenom razinom povjerenja, donosili zaključci o značajkama procesa ili proizvoda. Postoje razne metode planiranja pokusa te se najčešće primjenjuju u istraživanju utjecajnih faktora na karakteristike procesa ili proizvoda. Primjenom neke od procedura planiranja pokusa postižu se velike uštede ljudskih, vremenskih i financijskih resursa.

Faze pri izvođenju pokusa:

1. Definirati problem i cilj istraživanja
2. Odabrati utjecajne faktore i njihove razine
3. Odabrati mjerene vrijednosti (izlazne varijable)
4. Odabrati model pokusa
5. Izvesti pokus (predpokus, glavni pokus)
6. Analizirati rezultate
7. Formulirati zaključke i prijedloge

Shematski se pristup eksperimentiranju može predložiti metodom crne kutije koja je prikazana na slici 6. Stanoviti sustav (proces) se karakterizira pomoću ulaznih varijabli, koje mogu biti kontrolirane i nekontrolirane varijable, te izlazne varijable, odnosno odzivi sustava. U terminima statistike ulazne varijable su nezavisni, a izlazne zavisni čimbenici. Nepoznate i nekontrolirane varijable su uzrok pogreške mjerenja. Cilj eksperimenta je utvrditi njihovu uzročno posljedičnu vezu.



Slika 6. Metoda crne kutije

Kako bi se osigurala precizna procjena utjecaja čimbenika na izbor vrijednosti nezavisnih varijabli, potrebno je pravilno prikupiti podatke što ovisi o odabranom planu pokusa. Cilj statističkih metoda planiranja pokusa je pravi izbor plana za odabrani model s maksimalnom osjetljivošću prema procjeni parametara koja time osigurava bolju pouzdanost procjene. Metoda planiranja pokusa koristi se u

svrhu dobivanja što više informacija o istraživanom sustavu uz minimaliziran eksperimentalni i financijski angažman. Planiranje pokusa je vrlo važan alat u inženjerskom svijetu za poboljšavanje učinkovitosti u proizvodnom procesu, a ima i veliku primjenu u razvoju novih procesa. Primjena tehnika planiranja pokusa u ranom razvoju procesa može rezultirati:

1. Poboljšanim učinkom procesa
2. Smanjenom varijabilnosti i bližoj usklađenosti s nominalnim ili ciljanim zahtjevima
3. Smanjenjem vremena razvoja
4. Smanjenjem ukupnih troškova.

Metode planiranja pokusa imaju i važnu ulogu u djelatnostima projektiranja gdje su razvijeni novi proizvodi dok su postojeći proizvodi poboljšani.

Neke primjene planiranja pokusa u projektiranju uključuju:

- a) Procjenu i usporedbu osnovnih struktura planiranja
- b) Procjenu materijalnih mogućnosti
- c) Odabir parametara planiranja tako da proizvod radi dobro i u vrlo različitim uvjetima, tj. tako da je proizvod robustan¹
- d) Određivanje ključnih parametara koji utječu na izvedbu proizvoda.

Korištenje planiranja pokusa u ovim područjima može rezultirati proizvodima koji su lakši za proizvodnju, proizvodima koji imaju poboljšana svojstva i pouzdanost, nižim cijenama proizvoda, kraćim vremenom konstruiranja i razvoja.

3.3. Temeljna načela

Temeljna načela planiranja pokusa su vrlo važan dio svakog pokusa. Tri temeljna načela planiranja pokusa su replikacija, randomizacija i blokiranje. Pod replikacijom smatramo ponavljanje osnovnog pokusa. Repliciranje ima dva važna

¹ Robusan - proizvod ili proces koji se ponaša neprestano onako kako od njega tražimo i koji je relativno neosjetljiv na čimbenike koje je teško kontrolirati

svojstva. Prvo, dopušta ispitivaču da dobije procjenu greške pokusa. Ova procjena greške postaje osnovna mjerna jedinica za utvrđivanje jesu li uočene razlike u podacima stvarno statistički drugačije. Drugo, ako se koristi srednja vrijednost uzorka za procjenu utjecaja faktora u pokusu, tada replikacija dopušta ispitivaču dobivanje preciznijih procjena tog utjecaja.

Randomizacija je glavna okosnica korištenja statističkih metoda u planiranju pokusa. Pod randomizacijom podrazumijevamo da su obje alokacije materijala koji se ispituje i poredak kojim se pojedina mjerenja ili pokušaji pokusa izvode odabrane nasumično. Statističke metode zahtijevaju da opažanja ili greške budu neovisno raspodijeljene slučajnim varijablama, a randomizacija najčešće čini tu pretpostavku opravdanom i pomaže u osrednjavanju stranih utjecaja koji mogu biti prisutni.

Blokiranje je tehnika koja se koristi za povećanje preciznosti kod pokusa. Blok je dio pokusnog materijala koji bi trebao biti homogeniji od cijelog seta materijala. Blokiranje uključuje izradu usporedbi između utjecajnih uvjeta u pokusu i svakog bloka.

3.4. Smjernice za planiranje pokusa

Kako bi pravilno koristili statistički pristup u planiranju i analizi pokusa, bitno je sakupiti jasne podatke za kvalitetno razumijevanje kako će ti isti podaci biti analizirani.

Jedna od ključnih smjernica bitnih za analiziranje pokusa je razumijevanje problema. Iako se ovaj dio čini vrlo očit, ponekad u praksi nije jednostavno odrediti činjenice koje jednostavno opisuju problem. Obično je potrebno skupiti podatke s više područja koja se bave tim problemom (inženjerstvo, prodaja, proizvodnja...). Iz tog razloga je jako bitno skupiti tim iz više područja da bi se razvio kvalitetan plan pokusa.

Ispitivač mora odabrati faktore koji će analizirati u pokusu, domenu i razine u kojoj će ti faktori biti ispitani. Također se mora odlučiti kako će ti faktori biti

kontrolirani na željenim vrijednostima i kako će biti analizirani. Inženjer mora također odlučiti područje interesa za svaku varijablu.

U određivanju ključnih varijabli ispitivač mora biti siguran da će te varijable dati korisnu informaciju o procesu, a najčešće se dobivaju pomoću aritmetičke sredine ili standardne varijacije (ili oboje). Vrlo važan faktor je i sposobnost ocjenjivanja (ili greška mjerenja). Ako je sposobnost ocjenjivanja neprikladna, tada će relativno veliki faktori biti detektirani u pokusu ili će biti potrebno repliciranje. Prva tri koraka možemo nazvati pripremom pokusa. Uspješnost pokusa ovisi o kvaliteti postavljanja ovih točaka.

Odluka o planiranju uključuje veličinu uzorka, broj repliciranja, odabir odgovarajućeg redoslijeda ispitivanja varijabli i analiziranje ograničenja. Ovaj korak se vrlo lako može riješiti pomoću nekog programa. U odabiru plana je vrlo bitno biti objektivan jer se u mnogo pokusa već zna što će se dobiti kao rezultat. Najbitnije je odrediti koliko koja varijabla ima utjecaja na pokus.

Pri izvođenju pokusa vrlo je bitno paziti na to da se sve izvodi prema planu jer greške u ovom dijelu pokusa uništavaju vjerodostojnost pokusa. Planiranje unaprijed je od velike važnosti za uspjeh pokusa.

Statistička analiza podataka se koristi da bi se dobili objektivni rezultati i zaključci. Postoji mnogo odličnih softverskih paketa koji pomažu u analizi podataka. Često dolazimo do zaključka da su grafičke metode vrlo važne u analizi i interpretaciji. Statističke metode ne osiguravaju da faktor (ili faktori) imaju određeni utjecaj. Oni jedino pružaju smjernice pouzdanosti i vjerodostojnosti pokusa.

Nakon što su podaci analizirani, istraživač treba dati praktične zaključke i preporuke za dobivene rezultate i potrebne korake koji se moraju poduzeti za poboljšanje procesa. Uspješan pokus zahtjeva znanja o važnim faktorima, domena u kojima te faktore koristimo te pravilno mjerenje tih faktora. Odgovori na mnoga pitanja dobivaju se tijekom izvođenja procesa iz čega se zaključuje da je proces iterativan. Pokus se odvija u fazama i ne bi smjeli iskoristiti više od 25% iskoristivih resursa u prvom pokusu. To osigurava dovoljno resursa da se taj pokus izvede onoliko puta koliko je potrebno da se dobije objektivan zaključak o cjelokupnom procesu.


4. POTPUNI PLAN POKUSA (FAKTORSKI PLAN POKUSA)

U faktorskom planiranju proučavamo utjecaj promjene razina različitih faktora na proces. Svako ponovno ispitivanje ili replikacija uzima u obzir sve moguće kombinacije promjena razina faktora. Učinkovito faktorsko planiranje osigurava da se uz najmanji broj provedenih pokusa generira maksimalna količina informacija o tome kako ulazne varijable utječu na izlazne podatke procesa.

Broj izvedenih pokusa ovisi o broju faktora, ako imamo tri faktora tada će broj pokusa biti 2^3 tj. osam pokusa ili ako imamo pet faktora tada će biti 2^5 tj. 32 pokusa i slično. Više od pet faktora se kod potpunog plana ne preporuča zbog obujma pokusa.

Iznos promjena izlaznih podataka procesa uzrokovanih promjenom razine danog faktora naziva se ‘glavni učinak’ faktora.

Na slici 7. prikazan je potpuni plan pokusa sa dvije razine dvaju faktora, A i B. Razine faktora nazivamo ‘niska’ i ‘visoka’ i označavamo ih sa ‘-’ i ‘+’.



Slika 7. Grafički prikaz potpunog plana pokusa 2^2

Faktore možemo prikazati i kao kodirane (sa ‘-’ i ‘+’) u matrici procesa.

Tablica 1. Matrica kodiranih vrijednosti glavnih utjecaja

Glavni utjecaji		Izlazni podaci
A	B	Y
-	-	$y_1=20$
+	-	$y_2=40$
-	+	$y_3=30$
+	+	$y_4=52$

Glavni učinak faktora A ovdje je razlika između prosječne vrijednosti utjecaja (odziva) faktora A (na izlaze procesa) na najnižoj razini i prosječne vrijednosti odziva A na najvišoj razini.

$$A = \frac{(y_2 + y_4)}{2} - \frac{(y_1 + y_3)}{2}$$

$$A = \frac{(40 + 52)}{2} - \frac{(20 + 30)}{2} = 21$$

Povećavanje faktora A od niske prema visokoj razini uzrokuje prosječno povećanje odziva za dvadeset i jednu jedinicu.

S obzirom na to, glavni učinak faktora B je:


$$B = \frac{(y_3 + y_4)}{2} - \frac{(y_1 + y_2)}{2}$$

$$B = \frac{(30 + 52)}{2} - \frac{(20 + 40)}{2} = 11$$

Može se zaključiti kako faktor A ima veći odziv na izlazne podatke procesa budući da je njegov glavni učinak jednak dvadeset i jedan za razliku od glavnog učinka faktora B koji je jedanaest.

Kod nekih eksperimenata događa se da je razlika odziva između razina jednog faktora nije ista na svim razinama drugih faktora. To znači da je dolazi do međudjelovanja faktora.

Na idućoj slici prikazan je faktorski plan sa dva faktora:



Slika 8. Grafički prikaz potpunog plana pokusa 2^2

Pri nižoj razini faktora B (B^-), utjecaj A jest:

$$A = 50 - 20 = 30$$

Pri višoj razini faktora B (B^+), utjecaj A jest:


$$A = 12 - 40 = -28$$

Zbog toga što utjecaj faktora A ovisi o odabranoj razini faktora B zaključuje se da postoji međudjelovanje A i B. Razina učinka međudjelovanja jednaka je razlici između ova dva A učinka:


$$AB = \frac{(-28 - 30)}{2} = -29$$

Međudjelovanje ova dva faktora je veliko.

Slika 9. prikazuje odziv faktora A sa slike 7. za obje razine faktora B. Slika 10. prikazuje odziv faktora A sa slike 7. za obje razine faktora B. Linije na slici 9. nisu paralelne što ukazuje na međudjelovanje A i B.



Slika 9. Odziv faktora A bez međudjelovanja faktora B



Slika 10. Odziv faktora A sa međudjelovanjem faktora B

Grafovi poput ovih povremeno su veoma korisni, no ne bi se trebali koristiti kao isključiva tehnika za analizu podataka jer je njihova interpretacija subjektivna, a pojava često navodi na pogrešno mišljenje. Zato postoji drugo ilustrativno rješenje. Ako se pretpostavi da su oba faktora kvantitativna (poput temperature, tlaka, vremena i sl.), tada bi regresijski model prikazivanja za faktorski plan s dva faktora bio zapisan kao:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_{12} x_1 x_2 + \epsilon$$


gdje je y odziv, β_n parametri regresija čije vrijednosti moramo odrediti, x_1 je varijabla koja predstavlja faktor A, x_2 je varijabla koja predstavlja faktor B i ϵ oznaka nasumične pogreške. Varijable x_1 i x_2 definirane su kodiranom skalom od -1 do +1

(najniže i najviše razine A i B), a $x_1 x_2$ predstavlja međudjelovanje između x_1 i x_2 . U ovakvom regresijskom modelu, procjena parametara povezana je procjenom učinaka. Za slučaj na slici 7., tj. prema pronađenim glavnim učincima $A=21$ i $B=11$, odgovarajući parametri β_1 i β_2 dobiveni su kao $\frac{1}{2}$ glavnih učinaka. $\beta_1=10.5$ i $\beta_2=5.5$. Učinak međudjelovanja $AB=1$ pa je koeficijent međudjelovanja u regresijskom modelu $\beta_{12}=0.5$. Parametar β_0 procjenjuje se kao prosječna vrijednost sva četiri odziva, $\beta_0=35.5$. Shodno tome, regresijski model izgleda:

$$y = 35.5 + 10.5x_1 + 5.5x_2 + 0.5x_1x_2$$

Preko regresijskog modela uz pomoć odgovarajućih softvera moguće je dobiti trodimenzionalni prikaz koji nazivamo grafom odzivne površine kao i konturne linije konstantnih odziva.

Analogija rješavanja potpunog plana pokusa s više faktora, odnosno dobivanja glavnih utjecaja i međudjelovanja je ista kao i kod primjera dvije razine i dva faktora. Planiranje pokusa na dvije razine tri faktora (2^3) može se grafički prikazati pomoću kocke (slika 11).



Slika 11. Grafički prikaz potpunog plana pokusa 2^3

U matričnoj kodiranoj formi ovakav plan sa izlaznim vrijednostima možemo prikazati:

Tablica 2. Matrica kodiranih vrijednosti glavnih utjecaja za potpuni plan pokusa 2^3

Glavni utjecaji			Izlazni podaci	
A	B	C	Y	
-	-	-	y ₁	1
+	-	-	y ₂	a
-	+	-	y ₃	b
+	+	-	y ₄	ab
-	-	+	y ₅	c
+	-	+	y ₆	ac
-	+	+	y ₇	bc
+	+	+	y ₈	abc

U ovakvom pokusu sukladno prethodno prikazanim 2^2 pokusom, glavni utjecaj A može se izračunati prema formuli:

$$A = \frac{y_2 + y_4 + y_6 + y_8}{4} - \frac{y_1 + y_3 + y_5 + y_7}{4}$$

Na isti način dobivaju se glavni utjecaji B i C. Računanje međudjelovanja AB može se prikazati pomoću matrice (tablica 3.). Od srednje vrijednosti svih umnožaka faktora A i B koji daju pozitivnu vrijednost izlaza Y oduzmemo srednju vrijednost svih umnožaka koji daju negativnu vrijednost izlaza Y.

Tablica 3. Matrica kodiranih vrijednosti glavnih utjecaja i međudjelovanja za 2^3

Glavni utjecaji							Izlazni podaci
A	B	AB	C	AC	BC	ABC	Y
-	-	+	-	+	+	-	y ₁
+	-	-	-	-	+	+	y ₂
-	+	-	-	+	-	+	y ₃
+	+	+	-	-	-	-	y ₄
-	-	+	+	-	-	+	y ₅
+	-	-	+	+	-	-	y ₆
-	+	-	+	-	+	-	y ₇
+	+	+	+	+	+	+	y ₈

$$A = \frac{y_1 + y_4 + y_5 + y_8}{4} - \frac{y_2 + y_3 + y_6 + y_7}{4}$$

Na isti način dobivamo međudjelovanja AC, BC i ABC.

Budući da postoje tri glavna utjecaja (A, B, C), tri međudjelovanja dvaju faktora (AB, AC, BC) i međudjelovanje triju faktora (ABC), regresijski model za ovaj slučaj glasi:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{23} x_2 x_3 + \beta_{123} x_1 x_2 x_3 + \epsilon$$

pri čemu regresijski koeficijent β_0 dobivamo kao srednju vrijednost svih izlaza y, a ostale regresijske koeficijente dobivamo kao polovice vrijednosti odgovarajućih glavnih utjecaja odnosno međudjelovanja.

Osim potpunog plana pokusa s dvije razine i određenim brojem faktora postoji i potpuni plan pokusa tri razine i određenim brojem faktora (3^k). Kod takvog planiranja pokusa svaki faktor promatra se na tri razine: niskoj, srednjoj i visokoj, a

razine faktora kodirane su kao 0, 1 i 2. Potpuni plan pokusa tri razine i k faktora se koristi za istraživanje kvadratne veze između odziva i svakog pojedinog faktora.

Najznačajniji posebni slučaj potpunog plana pokusa je onaj koji smo već spomenuli, k faktora od kojih svaki ima samo dvije razine. Razine mogu biti kvantitativne (temperatura, tlak, vrijeme) ili kvalitativne (dva stroja, 'niska' i 'visoka' razina faktora i sl.). Ukupni broj ponavljanja kod takvog planiranja pokusa iznosi $2 \times 2 \times 2 \times \dots \times 2 = 2^k$ promatranja i naziva se 2^k planiranje pokusa (2^k faktorsko planiranje).

5. DJELOMIČNI PLAN POKUSA

Broj pokusa potpunih planova eksponencijalno raste s povećavanjem broja čimbenika. Na primjer, za pet čimbenika variranih na dvije razine potrebno je 32 pokusa (2^5), dok je za šest čimbenika potrebno 64 pokusa (2^6). Ako osoba koja vrši eksperimente može pretpostaviti da su određeni utjecaji višeg reda interakcija se mogu zanemariti te da su dovoljne informacije utjecaja glavnih čimbenika i da su za eksperiment dovoljne interakcije nižih redova čimbenika, tada se može koristiti djelomični plan pokusa.

Djelomični plan pokusa je među najčešće korištenim tipovima metoda za planiranje pokusa. Najčešće se koristi kod analitičkih analiza. U tim se eksperimentima uzima se u obzir velik broj čimbenika u svrhu utvrđivanja onih čimbenika koji imaju najviše utjecaja. Zato, ukoliko je broj čimbenika relativno velik, željene preliminarne informacije se mogu dobiti upotrebom samo pojedinog dijela potpunog plana, ako se međudjelovanja višeg reda (između više od dva čimbenika) mogu zanemariti. Pri tome se zanemaruju utjecaji međudjelovanja između tri i više čimbenika i promatra se utjecaj samo pojedinačnih čimbenika i eventualno međudjelovanja prvog reda. Na taj je način moguće odabrati dio potpunog plana i izostaviti određene pokuse. Broj pokusa je u tom slučaju $N = 2^{k-l}$ gdje je k ukupni broj čimbenika i l cijeli broj koji ukazuje na nepotpunost plana. Za $l = 0$, faktorski plan je potpun. U načelu, izabire se $1/2$, $1/4$, $1/8$ itd. potpunog plana, pri čemu izabrani kandidati trebaju biti uravnoteženi i ortogonalni. Pri konstrukciji 2^{k-l} matrice polazi se od 2^k matrice u kojoj je l čimbenika zamijenjena s određenim međudjelovanjima.

5.1. Rezolucija djelomičnih planova pokusa

Rezolucija djelomičnih faktorskih planova govori u kojoj mjeri su međudjelovanja žrtvovana za procjenu novih čimbenika i označuje se rimskim brojevima. Najčešće korištene rezolucije su III, IV i V.


Pri rezoluciji III glavni utjecaji nisu zamijenjeni s ostalim glavnim utjecajima, ali glavni utjecaji zamijenjeni su međudjelovanjem drugog reda. Kod

rezolucije IV glavni utjecaji nisu zamijenjeni s drugim glavnim utjecajima ili s međudjelovanjima drugog reda, ali su međudjelovanja drugog reda zamijenjena s drugim međudjelovanjem drugog reda. Kod rezolucije V međudjelovanja drugog reda su zamijenjena s međudjelovanjem trećeg reda. U tablici su prikazane korisne rezolucije za izradu djelomičnog plana pokusa.

Tablica 4. Korisne rezolucije za izradu djelomičnog plana pokusa

Broj čimbenika (k)	Specifikacija plana	Rezolucija	Broj pokusa (N)
3	23-1	III	4
4	24-1	IV	8
5	25-1	V	16
5	25-2	III	8
6	26-1	VI	32
6	26-2	IV	16
6	26-3	III	8
7	27-1	VII	64
7	27-2	IV	32
7	27-3	IV	16
7	27-4	III	8

U skladu s time, potpuni faktorski planovi imaju rezoluciju „beskonačno“. Na slici 12. je ilustriran princip konstrukcije djelomičnih planova na primjeru 2^{3-1} plana. Plan se sastoji od polovice pokusa 2^3 potpunog plana ($2^{3-1}=2^3/2=2^2$). Pri tome je treći čimbenik (C) zamijenjen s međudjelovanjem (AB).



Slika 12. Grafički prikaz plana s tri čimbenika na dvije razine:

(a) 2^3 punog faktorskog plana i (b) 2^{3-1} djelomičnog faktorskog plana

Na drugi način promatrano, 2^{3-1} djelomični plan se može shvatiti kao 2^2 plan (dva čimbenika na dvije razine), ali uz dodatak još jedne dimenzije - treći čimbenik. Navedeni plan ima rezoluciju III. Kod većeg broja čimbenika postoji mogućnost odabira rezolucije ovisno o broju pokusa.


5.2. Konstruiranje djelomičnog plana pokusa

Kod situacija u kojoj postoje tri faktora na dvije razine koje su od važnosti, a nema dovoljno resursa za testiranje svih kombinacija ($2^3=8$) nego na primjer za 1/2 pokusa, tada se koristi polovina faktorskog plana (2^{3-1}). Tablica 5. prikazuje matrični kodirani potpuni plan pokusa na dvije razine s tri faktora čije su kombinacije poslagane tako da ABC u prvoj polovici ima sve visoke razine međudjelovanja, a u drugoj sve niske.

Tablica 5. Razine čimbenika

Kombinacije	Glavni utjecaji							
	I	A	B	C	AB	AC	BC	ABC
a	+	+	-	-	-	-	+	+
b	+	-	+	-		+	-	+
c	+	-	-	+	+	-	-	+
abc	+	+	+	+	+	+	+	+
abc	+	+	+	-	+	-	-	-
ac	+	+	-	+	-	+	-	-
bc	+	-	+	+	-	-	+	-
(1)	+	-	-	-	+	+	+	-

Na tako konstruiranoj matrici odabiremo jednu od polovica matrice kao temelj za formiranje polovičnog plana pokusa (2^{3-1}). Uobičajeno je odabrati onu polovicu matrice u kojoj međudjelovanje ABC ima sve pozitivne vrijednosti isto kao i identifikacijski stupac I. Iz toga slijedi da je $I=ABC$ što predstavlja definirajuću relaciju za formiranje polovičnog 2^{3-1} plana pokusa. Moguće je odabrati i donju polovicu matrice gdje međudjelovanje ABC ima niske razine i u tom slučaju $I = -ABC$. U praksi se najčešće koristi prva navedena relacija.

Slika 13. Grafički prikaz 2^{3-1} djelomičnog plana pokusa

Prema tablici 5. glavni učinci A, B i C se dobiju prema slijedećim relacijama:

$$I_A = \frac{1}{2} (a - b - c + abc)$$

$$I_B = \frac{1}{2} (-a + b - c + abc)$$

$$I_C = \frac{1}{2} (-a - b + c + abc)$$

Može se zamijetiti da su utjecaji međudjelovanja jednaki glavnim utjecajima:

$$I_{BC} = \frac{1}{2} (a - b - c + abc)$$

$$I_{AC} = \frac{1}{2} (-a + b - c + abc)$$

$$I_{AB} = \frac{1}{2} (-a - b + c + abc)$$

Prema tome se može zaključiti da je $I_A = I_{BC}$, $I_B = I_{AC}$ i $I_C = I_{AB}$ stoga je nemoguće razlikovati A i BC, B i AC i C i AB. Kada se radi procjena glavnih utjecaja A, B, i C, zapravo se procjenjuje A+BC, B+AC, C+AB. Dva ili više čimbenika koji imaju ovo svojstvo nazivaju se aliasi. U ovom slučaju A i BC su aliasi, B i AC su aliasi i C i AB su aliasi. Ovo svojstvo se može isto tako odrediti preko identifikacijskog faktora I:

$$A \cdot I = A \cdot ABC = A2BC$$

Budući da je kvadrat bilo kojeg stupca jednak identifikacijskom stupcu I proizlazi da je:

$$A = BC$$

6. TAGUCHIJEVA METODA

Taguchi metoda je statistička metoda koju je razvio dr. Genichi Taguchi kako bi poboljšao kvalitetu proizvedenih dobara te se sve češće primjenjuje u biotehnologiji, marketingu i u oglašavanju. Hideki Aoyama je nadaleko poznat stručnjak u objašnjavanju i razumijevanju Taguchi metode. Također tijekom 1940-ih godina Taguchi je radio na unaprjeđenju Fisherove statističke metode kako bi bila primjenjiva u proizvodnji. Tijekom 1980-tih Taguchi je razvio metodu za pronalaženje produkata proizvodnje visoke kvalitete bez obzira na varijacije procesnih parametara. Takvi procesi se nazivaju robusnim procesima budući da su neosjetljivi na šumove. Metoda je vrlo popularna u industriji radi jednostavnosti pristupa i potakla je razvoj nove proizvodne filozofije. G. Taguchi je u SAD-u poznat kao vođa pokreta industrijske kvalitete. Danas se dr. G. Taguchi bavi konzaltingom u Japanu.

Taguchi je razvio cjelokupnu filozofiju i udružene metode za inženjering kvalitete, a jedna od njegovih najvažnijih ideja temelji se na tome da je kvalitetan proizvod onaj koji izaziva najmanje troškove, izražene novcem, prema društvu tijekom cijeloga svojeg „životnog vijeka“. Odnos između gubitka i tehničkih osobina proizvoda izražava se funkcijom gubitka. Kvaliteta mora biti ugrađena u proizvod i procese proizvodnje te u proizvodnom procesu treba posvetiti više pažnje „off-line“ kontroli kako bi se uklonili problemi koji se javljaju u proizvodnji.

Različiti tipovi uvjeta odnosno promjena (npr. tolerantne varijacije, vanjski uvjeti, „rasipanje“ susjednih sustava itd.) uzrokuju različite devijacije na sustavu umanjujući njegov optimalan rad. Kako bi se izbjegao porast takvih promjena, potrebno je razviti robusne proizvode – funkcioniraju optimalno i u različitim promjenjivim uvjetima. Pronalaženje dizajnerskih parametara koji povećavaju robusnost temelj je Taguchi metode. Robusni dizajn nije izravno usmjeren na rješavanje problema, već kreiranje sustava koji funkcionira približno idealnoj funkciji u svim uvjetima.


Sve navedeno govori da su Taguchi metode sustav inženjeringa kvalitete okrenut ka smanjivanju troškova. Ova metoda daje naglasak na učinkovitu primjenu inženjerskih strategija radije nego na primjenu naprednih statističkih metoda.

Taguchijeve su metode poznate i kao inženjering kvalitete, a sadrže sljedeće odrednice:

- dizajniranje parametara
- određivanje varijacija
- idealnu kvalitetu
- off-line kontrolu kvalitete
- funkciju gubitka kvalitete
- omjer „signala i šumova“
- filozofiju robusnog dizajna.

Kada je riječ o idealnoj kvaliteti proizvoda, u odnosu na ostale teoretičare, G. Taguchi se nije slagao s tradicionalnim specifikacijama dizajna te je kreirao vlastitu filozofiju „idealne kvalitete“. Prema G. Taguchiju kvaliteta proizvoda trebala bi imati određenu ciljnu vrijednost koja pobliže označuje kritičnu karakteristiku proizvoda. Smatrao je da cilj proizvodnje ne treba biti samo kvalitetan proizvod, već trajni kvalitetni proizvod koji realizira svoju funkciju kroz cijeli svoj životni vijek. Iz ove filozofije, G. Taguchi je razvio koncepciju robusnog dizajna.

Ova se nova koncepcija odnosi na proizvodnju proizvoda i usluga visoke kvalitete koji nemaju pogrešaka. Ovaj dizajn ima visoku toleranciju na faktore koje nije moguće kontrolirati te se G. Taguchi založio, pomoću unutrašnjeg i vanjskog dizajna, uzeti u obzir faktore buke (vanjske) i faktore dizajna (unutrašnji). Na ovaj način nastoji proizvesti proizvode koji neće imati pogrešaka, ali će jamčiti funkcioniranje i nakon planiranog vremena. Na primjer, u automobilske industriji inženjeri testiraju razinu tolerancije proizvoda putem tehnike pouzdanosti zvane testiranje ubrzanog života. Ova koncepcija dizajna treba proizvod učiniti pouzdanijim i visoko tolerantnim.



Slika 14. Konceptcija robusnog dizajna

Funkcija gubitka kvalitete: G. Taguchi sugerira da proizvođači prošire svoje horizonte uzimajući u obzir troškove društva izazvane odstupanjima proizvoda od željenih karakteristika. Iako kratkoročni troškovi mogu jednostavno biti neprilagođeni, svaki proizvod proizveden izvan nominalnog rezultira će nekim gubitkom za kupca ili šire društvo kroz brzu istrošenost. Ti su gubici evidentni, ali proizvođači ih uobičajeno ignoriraju jer su više zainteresirani za vlastite troškove nego troškove društva. U ekonomiji, teorija kaosa predviđa da oni štite tržište od operativne učinkovitosti. G. Taguchi govori, da će takvi gubici svojevremeno i neizbježno pronaći put natrag u kompaniju gdje su nastali (efekt sličan tragediji sličnosti) te da će proizvođači radeći na njihovom smanjivanju povećati svoju reputaciju, osvojiti tržište i ostvariti profit. Takvi su troškovi naravno mali kada je proizvod blizu nominalne vrijednosti. Kako se udaljava od nominalne vrijednosti, gubici rastu do one točke gdje postaju previsoki da bi se zaniijekali. Uvijek postoji određena granica. G. Taguchi želi naći učinkovit način njihova statističkog predstavljanja te definira tri situacije:

1. Manje je bolje – u slučajevima kada je ciljana vrijednost odziva oko nule (npr. emisija štetnih plinova, potrošnja energije):

$$(S/N)_j = -10 \log \frac{1}{n} \sum_{i=1}^n [y_{ij}^2], j = 1 \dots m$$

2. Više je bolje – u slučajevima kada se teži maksimalnoj ciljanoj vrijednosti odziva (npr. prinos produkta, konverzija reaktanata u produkte):

$$(S/N)_j = -10 \log \left[\frac{1}{n} \sum_{i=1}^n \left[\frac{1}{y_{ij}^2} \right] \right], j = 1 \dots m$$


3. Sredina je najbolje – u slučajevima kada se teži srednjoj ciljanoj vrijednosti odziva (npr. veličina čestica, svojstva produkta):

$$(S/N)_j = -10 \log s^2, j = 1 \dots m$$

Pri čemu je s^2 varijanca:

$$s^2 = \sum_{i=1}^n \left(\frac{(y_{ij} - \bar{y})^2}{n - 1} \right)$$

Prva se dva slučaja prikazuju jednostavnom monotonom funkcijom gubitka, a u trećem slučaju je Taguchi razvio funkciju kvadratnog modela gubitka.



Slika 15. Grafički prikaz funkcije gubitka kvalitete

Taguchijeva funkcija gubitka kvalitete definira tri osnovna pravila:

- određivanje specifikacija – prvo i najvažnije je odrediti prijetnje
- određivanje cilja s minimalnim odstupanjima
- određivanje prikladnih ciljnih vrijednosti za pojedine proizvode
- dozvoljavanje nekih varijacija – smanjivanje varijacija te prilagodba prosjeka cilju.

Taguchi metoda bavi se takozvanim off-line fazama planiranja gdje na modelima, prototipu i simulacijama traži kombinacije parametara i različitih učinaka. To dovodi do, već spominjanih, robusnih proizvoda, tj. procesa koji su manje osjetljivi na različite promjene i smetnje u samoj proizvodnji i tijekom uporabe. Taguchi je shvatio da je najbolja prilika za otklanjanje varijacija za vrijeme dizajniranja proizvoda u samom proizvodnom procesu. Dosljedno tome razvio je strategiju kvalitetnog inženjerstva koje se može koristiti u oba konteksta.

Proces ima tri faze:

- određivanje sustava
- određivanje parametara
- određivanje tolerancije odstupanja.

Kod određivanja sustava Taguchi metodom bitno je odgovoriti na pitanje „kako će sustav najbolje zadovoljavati potrebe kupaca“. Izrada se organizira na konceptualnoj razini, uključujući kreativnost i inovativnost, te zahtijeva tehnička znanja iz znanosti i inženjeringa. Važno je znati planirati sustav koji funkcionira unutar određenih nominalnih uvjeta. Kada je postavljena koncepcija, treba odrediti nominalne vrijednosti različitih dimenzija i dizajnerskih parametara te detaljno odrediti fazu dizajniranja konvencionalnog inženjerstva. Važno je odrediti parametre koji se mogu kontrolirati. Taguchijeva radikalna domišljatost uočljiva je u tome što se zahtijeva točan izbor vrijednosti i to ispod određenih vrijednosti izvedbenih zahtjeva sustava. U mnogim okolnostima, ovo omogućava da parametri budu izabrani kako bi minimizirali efekte izvedbenih varijacija na proizvodnju, okoliš i ukupnu štetu odnosno robustifikaciju. Faktori koji se mogu postaviti i održavati zovu se kontrolni faktori. Kada je uspješno dovršeno određivanje parametara i razumijevanje efekata različitih parametara na izvedbu, resursi se mogu usmjeriti na smanjivanje i

kontroliranje varijacija u nekoliko kritičnih dijelova (Paretovo pravilo). Važno je odrediti uže rangove tolerancije za one faktore čije promjene mogu negativno utjecati na promjenu proizvoda ili procesa.

Kroz ove faze možemo uočiti razlike između tradicionalnog načina planiranja i Taguchi metode. Kod tradicionalnog planiranja u prvom planu je rješavanje problema, dok je kod Taguchi metode važno izbjegavanje, odnosno sprječavanje problema. Tradicionalna metoda planiranja polazi od izbora, izrade prototipa, preko mjerenja i određivanja stope tolerancije do konačnog rezultata proizvodnje uz bitno smanjene troškove proizvodnje.


Primjer primjene Taguchi metode nalazimo u talijanskoj kompaniji Pirelli koja proizvodi automobilske gume. Tehničari u Pirelliju pokušavali su se riješiti neugodnog zvuka koji je proizvodio jedan od remena za usklađivanje. Metoda pokušaja i pogreške (smanjivanje i povećanje dimenzija remena, razni oblici montaže i sl.) bila je mukotrpna i nije urodila plodom. Tada su pozvani tehničari iz Taguchijevog instituta te su u vrlo kratkom vremenu otkrili izvor zvuka - problem je bio u materijalu remena. Kada se promijenio materijal, ne samo da je nestao neugodan zvuk, već se i životni vijek remenu udvostručio. Troškovi zamjenskog materijala bili su isti kao i kod originalnog.

6.1. Primjena Taguchija u planiranju pokusa

Glavna ideja Taguchijeve metodologije je primjena tehnika planiranja pokusa s ciljem definiranja razina kontroliranih čimbenika koji čine proces robusnim i uz prisutnost nekontroliranih čimbenika (šumova). Pri tome prisutni šumovi imaju velik utjecaj na odziv procesa, odnosno kvalitetu proizvoda, a nije ih moguće kontrolirati ili je ekonomski prezahtjevno da se održavaju na određenoj konstantnoj vrijednosti. Šumovi su glavni razlog pojave varijacije u sustavu. Taguchijevom metodom se kvaliteta produkta definira kao odstupanje odnosno devijacija stanovitog odziva od željene vrijednosti.

Pokusi se provode na način da se utvrdi raspon varijabilnosti nastao kao posljedica variranja kontroliranih čimbenika i nekontroliranih čimbenika (šumova). Taguchi preporuča korištenje ortogonalne matrice plana pokusa, potpuni plan pokusa,

jedan za svaki od dvije grupe čimbenika (kontrolirane varijable i šumovi). Za razliku od tradicionalnog Fisherovog pristupa koji podrazumijeva da se greška distribuira nasumično unutar plana, Taguchijev plan omogućuje analizu utjecaja greške (šumova) na odziv.



Slika 16. Dijagram vanjske matrice 2^2 uvjeta šumova (E) i unutarnje matrice 2^3 uvjeta procesnih parametara (X) Taguchijevog plana pokusa

Razine procesnih parametara formiraju takozvanu unutarnju matricu, dok potpuni plan šumova čini vanjsku matricu. Vanjska matrica se sastoji od četiri retka, $n=2^2$ (2-razine, 3-čimbenika potpuni plan), dok unutarnja matrica ima osam stupaca, $m=2^3$ (2-razine, 3-čimbenika potpuni plan). Takav Taguchijev plan je slikovito prikazan kao klasični plan kontroliranih čimbenika koji čini unutarnju matricu, uz dodatak vanjske matrice šumova u svaki kut unutarnje matrice (slika 16).

Na taj način imamo $2^2 \times 2^3 = 32$ definirana eksperimentalna uvjeta i odziv procesa se motri za svaki set uvjeta (y_{ij}) te se računa signal-šum omjer (S/N) za svaku točku unutarnje matrice. Pri tome kombinacija razina kontroliranih čimbenika koja odgovara najvećoj vrijednosti S/N predstavlja najrobusnije uvjete proizvodnje u granicama ispitivanih utjecaja šumova.

7. METODA ODZIVNE POVRŠINE

Metoda odzivne površine (engl. Response Surface Methodology, RSM) je skup matematičkih i statističkih metoda kojima se modeliraju i analiziraju utjecaji nekoliko faktora (nezavisne varijable) na promatrani odziv. Odziv je mjerljiva veličina kvalitete proizvoda ili procesa. Kada se jednom ustanovi zakonitost ili odnos nezavisnih varijabli preko matematičkog oblika, odzivne funkcije, takav oblik opisa pojave može poslužiti za donošenje konkretnih zaključaka o prirodi pojave i biti dobrom podlogom optimiranju poznatim metodama optimizacije. U prošlom stoljeću RSM se razvijao na području pokusa vezanih za istraživanje procesa u kemijskoj industriji, nakon čega se uporaba proširila i na ostala područja industrijskih i znanstveno istraživačkih područja, posebice u područjima razvoja novih materijala i postupaka. Stoga se može zaključiti da je metoda odzivne površine postala jednim od osnovnih alata u planiranju i analizi pokusa. Danas je nezamislivo planirano eksperimentiranje bez uporabe suvremenih programskih paketa koji se bave područjem planiranja i analize pokusa, a sadržavaju tehnike planiranja i optimizacije koje su bazirane na metodologiji odzivne površine.

Osnovna ideja metodologije odzivne površine jest dobiti odnos utjecajnih (nezavisnih) faktora na zavisnu varijablu (odziv) kroz odzivnu funkciju. Također je moguće razlučiti efekte pojedinih članova modela, kao glavne efekte ili interakcije. Kao uvjet za uporabu RSM-a trebaju postojati barem dvije nezavisne varijable (x_1 i x_2) i jedna zavisna varijabla (y). Rezultat procesa (zavisne varijable) je moguće formulirati preko izraza:

$$y = f(x_1, x_2) + \varepsilon$$

gdje je ε pogreška ili šum koji se javlja u odzivu y . Nadalje, očekivana vrijednost odziva može se formulirati preko sljedećeg izraza:


$$E(y) = f(x_1, x_2)$$

To je ujedno i oblik odzivne površine. Odzivna površina može se i prikazuje se grafički u cijelom eksperimentalnom području, području mogućih kombinacija faktora. Kako bi se lakše vizualizirala odzivna površina dvodimenzionalnim

prikazom, upotrebljava se i konturni dijagram koji u suštini daje konture odzivne površine.

Konačni cilj RSM-a je određivanje optimalnih uvjeta procesa i sustava ili utvrđivanje područja faktora u kojem su radne specifikacije ili ograničenja zadovoljena.

Ako su proučavani faktori u pokusu doista oni koji utječu na proces, a podaci dobiveni pokusom prihvatljive točnosti i preciznosti, tada je moguće razviti model koji vjerodostojno opisuje proces. Razvojem, tj. dodavanjem centralnog stanja pokusa te stanja pokusa jednako udaljenih od centralne točke (aksijalnih točaka) na postojeći faktorski plan pokusa na dvije razine formira se centralno kompozitni plan pokusa. Stoga, centralno kompozitni plan pokusa je model I. reda ($2k$) proširen dodatnim točkama (stanjima pokusa) u centru i točkama u osima da bi se omogućila procjena parametara modela II. reda. Centralno kompozitni plan pokusa sastoji se od $2k$ stanja u vrhovima (faktorska stanja), $2k$ stanja u osima i stanja u središtu (k – broj faktora). Centralna točka daje informaciju o nelinearnosti u odzivu dok aksijalne točke daju mogućnost efikasne procjene parametara drugog reda. Ukupno gledajući, svaki faktor varira se na pet razina. Za $k = 3$ (faktori su x_1, x_2, x_3) na slici 17. prikazan je model centralno kompozitnog pokusa.



Slika 17. Centralno kompozitni plan pokusa za tri faktora

Ukupni broj pokusa u centralno kompozitnom planu iznosi:

$$N = 2^k + 2k + n_c$$

pri čemu je n_c broj ponavljanja točke centra. Izbor vrijednosti α i n_c određuje karakteristiku plana, odnosno njegovu ortogonalnost i rotatabilnost, što ovisi o broju čimbenika i broju ponavljanja istovrsnih uvjeta. Pokus je ortogonalan ako je zbroj produkata kodiranih stanja bilo kojih dviju kolona u matrici pokusa jednak nuli. Rotatabilnost centralno kompozitnog plana pokusa postiže se dodavanjem stanja pokusa tako da su sva stanja jednako udaljena od središta pokusa, odnosno rotatabilnost ovisi o tzv. osnovj udaljenosti α (udaljenosti stanja u osima od centra).

Pokus je rotabilan ako je:

$$\alpha = \sqrt{F}$$

gdje je F broj faktorskih stanja, $F=2k$.

Prema tome, u slučaju dva faktora $\alpha = 1,414$, a u slučaju tri faktora $\alpha = 1,682$.

8. EKSPERIMENTALNI DIO

8.1. Primjer metode odzivne površine

Cilj eksperimentalnog dijela je utvrđivanje utjecaja faktora MAG zavarivanja na mehanička svojstva čelika API 5L X80 čije je mjerenje provedeno za potrebe doktorskog rada² na Fakultetu strojarstva i brodogradnje. Varijacijom unosa topline, temperature predgrijavanja i sastava plinske zaštite, mijenjali su se uvjeti zavarivanja te se naknadnim ispitivanjima proučavao njihov učinak na mehanička svojstva zavarenog spoja. Postavljanjem uvjeta razmatranja faktora, odlučeno je da će se parametri čiji se utjecaj razmatra svesti na tri faktora (ulazne varijable): unos topline, temperatura predgrijavanja te vrsta zaštitnog plina, i dvije mjerne vrijednosti odnosno udarnu snagu loma na zavar i ZUT (zona utjecajne topline). Kako se promatra međusobni utjecaj triju zasebnih faktora, u slučaju potpunog faktorskog pokusa bilo bi potrebno 27 stanja pokusa. Zbog smanjenja vremena izvođenja eksperimentalnog dijela te smanjenja troškova, broj izvedenih stanja pokusa smanjen je na 17. To je omogućeno korištenjem centralno kompozitnog plana pokusa za tri faktora. Korištenjem takvog plana pokusa smanjuje se potreban broj stanja pokusa bez znatnijeg utjecaja na kvalitetu dobivenih rezultata.

Od odabrana tri faktora, svi su kontinuirani (x_1 - udio CO_2 u Ar, x_2 - unos topline i x_3 - temperatura predgrijavanja). Sukladno tome α iznosi 1,682, a ponavljanje stanja pokusa u centru određeno je da se izvodi tri puta kako bi se što bolje procijenila pogreška pokusa, "čista pogreška" (eng. pure error).

Dodatna stanja u centru pokusa služe da bi se mogle usporediti vrijednosti mjerenja zavisne varijable u središtu pokusa s aritmetičkom sredinom za ostatak pokusa. Ako je aritmetička sredina centra pokusa značajno različita od ukupne aritmetičke sredine svih ostalih stanja pokusa, tada se može zaključiti da veza između faktora pokusa i zavisne varijable nije linearna. Ako se pokus barem djelomično ponavlja, tada se može procijeniti pogreška pokusa iz varijabilnosti ponovljenih stanja. Budući da se ta stanja izvedu pod identičnim uvjetima, odnosno identičnim razinama faktora, procjena pogreške pokusa iz tih podataka neovisna je o tome je li

² D. Kolednjak; Utjecaj parametara zavarivanja na strukturu i svojstva čelika API 5L X80; Doktorski rad, Fakultet strojarstva i brodogradnje, Zagreb, 2014.

model pokusa linearan ili nelinearan te sadržava li interakcije višeg reda. Tako je procijenjena pogreška pokusa "čista pogreška", odnosno ona je posljedica samo nesigurnosti mjerenja zavisne varijable. Stoga se može zaključiti da broj centralnih točaka n_c često bitno utječe na distribuciju procijenjene varijance u eksperimentalnom području.

Prema gornjoj formuli, $N = 2^k + 2k + n_c$, minimalni broj stanja pokusa iznosi $N = 9$. Međutim, kako je odabrano tri točke centra ($n_c=3$) broj stanja pokusa je:

$$N = 2^k + 2k + n_c = 2^3 + 2 \times 3 + 3 = 17$$

Raspon vrijednosti ulaznih faktora je određen prema tehničkim mogućnostima, a prikazan je u tablici 6. s gornjim i donjim vrijednostima za svaki faktor.

Tablica 6. Rasponi faktora

	Gornja vrijednost	Donja vrijednost
x_1 -Udio CO ₂ u Ar (%)	28	8
x_2 - Unos topline (KJ/cm)	15	8
x_2 – Temperatura predgrijavanja (°C)	140	21

Razine faktora određene su prema matrici stanja pokusa za centralno kompozitni plan pokusa s tri faktora.

Tablica 7. Faktori i njihove razine

Razina	x_1 Udio CO ₂ u Ar (%)	x_2 Unos topline (KJ/cm)	x_2 Temperatura (°C)
-1.68	8	8	21
-1	12	10	45
0	18	12	80
1	24	14	115
1.68	28	15	140

Nakon izvođenja pokusa i izvršenog mjerenja, pomoću F – testa će se analizirati varijanca, odnosno utvrditi značajnost doprinosa pojedinih parametara te utvrditi međusobni utjecaj faktora analizom efekata. Model ovisnosti će se opisati regresijskom jednadžbom višeg reda te će se analizirati greške u eksperimentalnom prostoru i pritom detektirati nelinearnosti u odnosima. Nakon što se odredio cilj i problem istraživanja, utjecajni faktori, mjerne veličine i model pokusa mora se još objasniti i pristup testiranju statističkih hipoteza. Statistička hipoteza matematički je izraz koji predstavlja polaznu osnovu na kojoj se temelji kalkulacija statističkog testa dok testiranje statističkih hipoteza predstavlja postupak donošenja odluke na bazi uzorka (uzorak-n podataka: 1,2,...,n).

Rezultati se uzorka mogu shvatiti kao točka u n-dimenzionalnom prostoru koji se može podijeliti na dva dijela koji se međusobno isključuju (dio A i dio B).

Dvije hipoteze:

- I. nulta hipoteza: $H_0 \dots \Delta \bar{x}_1 = \Delta \bar{x}_2 = \dots = \Delta \bar{x}_n$
nema signifikantnog utjecaja faktora (varijacije su nesignifikantne)
- II. alternativna hipoteza: $H_1 \dots$ bar jedan $\Delta \bar{x}_n \neq 0$
ima signifikantnog utjecaja faktora (varijacije su signifikantne)

Pri uporabi opisanog modela moguće su pogreške pri testiranju hipoteza, a uzrok pogrešaka jest slučajnost odabira elemenata uzorka. Pogreška prve vrste nastaje odbacivanjem nulte hipoteze H_0 i prihvatanjem alternativne hipoteze H_1 iako je hipoteza H_0 ispravna. Njena vjerojatnost jest:

$$\alpha = P\{T \in B/H_0\}$$

(pogrešno odbacivanje hipoteze H_0).

Rezultati mjerenja statistički su obrađeni pomoću programskog paketa Design Expert 7 te su pomoću navedenog programskog paketa izrađeni matematički modeli za opisivanje utjecaja ulaznih faktora na mjerenu veličinu. Prikladnost modela određivana je pomoću F-testa te na temelju maksimalne vrijednosti koeficijenta determinacije, R-kvadrata ("Adjusted R-Squared" i "Predicted R-Squared").

Značajnost modela i članova odzivnog polinoma određivana je analizom varijance ("ANOVA"). Redoslijed izvođenja plana pokusa je rezultat generiranja slučajnog redoslijeda programom Design Expert kako bi se zadovoljila stohastika. Zbog praktičnih razloga pojedini pokus je označen upravo brojem dobivenim slučajno generiranim redoslijedom izvođenja radi lakšeg unosa podataka nakon mjerenja, kao i njihove analize.

Tablica 8. Stanje pokusa stohastički generirano programom Desing Expert

Select	Std	Run	Factor 1 A:udio CO2 u A %	Factor 2 B:unos topline KJ/cm	Factor 3 C:temperatura C	Response 1 Udarni rad loma KV(J/cm2)	Response 2 Udarni rad loma KV(J/cm2)
	1	4	12.00	10.00	45.00	167.7	365.7
	2	17	24.00	10.00	45.00	149.7	342.6
	3	7	12.00	14.00	45.00	145.7	334.9
	4	15	24.00	14.00	45.00	129.1	348.3
	5	14	12.00	10.00	115.00	162	357.4
	6	11	24.00	10.00	115.00	151.1	363.4
	7	1	12.00	14.00	115.00	181.4	337.6
	8	9	24.00	14.00	115.00	140.4	335.6
	9	5	7.91	12.00	80.00	173.9	283.1
	10	10	28.09	12.00	80.00	117.7	251.7
	11	13	18.00	8.64	80.00	135.6	256.2
	12	12	18.00	15.36	80.00	123	269
	13	3	18.00	12.00	21.14	114.4	281.8
	14	16	18.00	12.00	138.86	147.2	289.8
	15	2	18.00	12.00	80.00	107.7	249.6
	16	6	18.00	12.00	80.00	117.1	289.3
	17	8	18.00	12.00	80.00	119	272.2

Kod linearnog modela pojavljuju se samo članovi nultog reda, faktori, i članovi prvog reda te njihove interakcije. Kod modela viših redova još se pojavljuju interakcije viših redova koje u tehničkim sustavima često mogu imati zanemariv utjecaj zbog čega se pristupa redukciji izrađenog modela natražnom metodom. Redukcija modela se provodi eliminacijom unatrag, tj. isključivanjem neznačajnih članova čija vrijednost "Prob>F" je veća od 0,05. Svi članovi čija je vrijednost

”Prob>F” manja od 0,05 sačinjavaju model. Ne treba uvijek odbaciti članove čije su ”Prob>F” vrijednosti malo veće od 0,05 jer to može biti rezultat odstupanja u mjerenju ili sl. Ovakvim pristupom redukciji modela eliminacijom unatrag, svi članovi imaju mogućnost uključivanja te je dobiveni model znatno robustniji od pristupa uključivanjem unaprijed. Nakon opisane eliminacije dobio se model prikazan na slici 18. odnosno članovi koji su uključeni u model jer su značajni za model.

Intercept	M
A-udio CO2 u Ar	M
B-unos topline	M
C-temperatura predgrijavanja	M
AB	
AC	
BC	
A ²	M
B ²	M
C ²	M
ABC	
A ² B	
A ² C	
AB ²	
AC ²	~
B ² C	~
BC ²	~
A ³	~
B ³	~
C ³	~

Slika 18. Model

Na tablicama 9 i 10. prikazani su rezultati obrade u programskom paketu Design Expert modulom ANOVA (analiza varijance).

Tablica 9. Rezultati analize varijance za zavar

Response	1	Udarni rad loma (Zavar)				
ANOVA for Response Surface Reduced Quadratic Model						
Analysis of variance table [Partial sum of squares - Type III]						
	Sum of		Mean	F	p-value	
Source	Squares	df	Square	Value	Prob > F	
Model	6254.16	6	1042.36	5.96	0.0070	significant
A-udio CO2 u.	2399.31	1	2399.31	13.71	0.0041	
B-unos topline	222.23	1	222.23	1.27	0.2861	
C-temperatura	701.27	1	701.27	4.01	0.0732	
A²	2458.53	1	2458.53	14.05	0.0038	
B²	899.80	1	899.80	5.14	0.0468	
C²	1009.80	1	1009.80	5.77	0.0372	
Residual	1750.19	10	175.02			
Lack of Fit	1676.97	8	209.62	5.73	0.1571	not significant
Pure Error	73.22	2	36.61			
Cor Total	8004.34	16				

Tablica 10. Rezultati analize varijance za ZUT (model nije značajan)

Response	2	Udarni rad loma (ZUT)				
ANOVA for Response Surface Linear Model						
Analysis of variance table [Partial sum of squares - Type III]						
	Sum of		Mean	F	p-value	
Source	Squares	df	Square	Value	Prob > F	
Model	461.05	3	153.68	0.072	0.9737	not significant
<i>A-udio CO2 u.</i>	250.66	1	250.66	0.12	0.7367	
<i>B-unos topline</i>	191.75	1	191.75	0.090	0.7686	
<i>C-temperatura</i>	18.64	1	18.64	8.776E-003	0.9268	
Residual	27610.47	13	2123.88			
<i>Lack of Fit</i>	26817.39	11	2437.94	6.15	0.1481	not significant
<i>Pure Error</i>	793.09	2	396.54			
Cor Total	28071.52	16				

Kada su vrijednosti "Prob>F" za određene članove odzivnog polinoma manje od 0,05 onda su ti članovi značajni. To znači da je vjerojatnost dobivanja tako velike F vrijednosti uslijed šuma manja od 5%. Kako se iz tablice 10. rezultata analize varijance za ZUT vidi da model nije značajan u daljnjoj analizi ga više nećemo koristiti, već ćemo koristiti podatke samo za zavar. Naime, pravi smisao p-vrijednosti

je u testiranju hipoteze H_0 prema alternativnoj hipotezi H_1 , odnosno p-vrijednost pokazuje vjerojatnost postizanja F vrijednosti ako se prihvati H_0 , tj. ako nema utjecaja faktora. Male p-vrijednosti upućuju na odbacivanje H_0 i prihvatanje alternativne hipoteze H_1 , tj. ukazuju da postoji značajan utjecaj parametra na promatranu izlaznu veličinu. Vjerojatnost odgovara površini ispod krivulje F-razdiobe koja je određena pripadajućom F vrijednosti. Formalno se p-vrijednost definira kao najniža razina signifikantnosti koja rezultira odbacivanjem H_0 .

U nastavku su objašnjene veličine koje su korištene za analizu i vrednovanje kvalitete izrađenih matematičkih modela.

"R-Squared" je koeficijent determinacije koji predstavlja procjenu ukupne varijacije podataka objašnjenih pomoću modela odnosno mjera odstupanja od aritmetičke sredine koja je objašnjena modelom, što je R^2 bliži 1, to model bolje slijedi podatke, odnosno pojava je bolje objašnjena. Izračunava se prema izrazu :

$$R^2 = 1 - \frac{SKO_{ostatka}}{SKO_{model} + SKO_{ostatka}}$$

gdje je SKO- suma kvadrata odstupanja.

"Adjusted R-Squared" je R-kvadrat prilagođen broju članova modela u odnosu na broj stanja pokusa.

"Predicted R-Squared" je mjera iznosa varijacija u novim podacima objašnjenim pomoću modela.

Oba R-kvadrata ("Adjusted R-Squared" i "Predicted RSquared") trebala bi biti blizu jedinice, a ako su jednaki jedinici onda je 100% varijacije promatranih vrijednosti objašnjeno modelom. Ukoliko je "Adjusted R-Squared" veći od 75% model se može smatrati značajnim.

"Lack of fit" je veličina koja govori o varijaciji vrijednosti mjerene veličine kod ponavljanja istovjetnih stanja plana pokusa oko njihovih prosječnih vrijednosti. Ako je ova vrijednost značajna, to znači da je varijacija ponovljenih stanja pokusa veća od varijacije vrijednosti za pojedino stanje pokusa predviđeno modelom. Analiza se provodi tako da se izračuna F_0 vrijednost za izrađeni model.

"Pure Error" je pogreška ponavljanja pojedinih stanja pokusa u svrhu procjene varijance odziva kao i broja stupnjeva slobode za adekvatno statističko testiranje izrađenog modela.

"Adequate precision" je mjera raspona predviđenog odziva u odnosu na njegovu grešku, radi se o omjeru signal-šum. Poželjno je da je omjer veći od 4.

"PRESS" je predviđena suma kvadrata ostataka.

"C. V." je koeficijent varijacije relativna mjera rasipanja izražena u % koja se izračunava prema izrazu:

$$C.V. = \frac{s}{\bar{x}} \times 100$$

Veći koeficijent varijacije pokazuje veću raspršenost, odnosno manju reprezentativnost aritmetičke sredine. Koeficijent varijacije može i prijeći vrijednost 100% u slučajevima kad se radi o veoma heterogenom nizu.

U tablici 11. prikazani su osnovni statistički podaci o dobivenom modelu koji opisuje kvalitetu izrađenog modela.

Tablica 11. Pregled statističkih podataka modela za Zavar

Std. Dev.	13,23	R-Squared	0,7813
Mean	140,16	Adj R-Squared	0,6502
C.V. %	9,44	Pred R-Squared	0,1968
PRESS	6429,27	Adeq Precision	7.546

Nakon što se provede statistička obrada dobivenih vrijednosti pokusa očekuje se dobivanje matematičkih modela oblika prikazanog izrazom:

$$Y = b_0 + \sum_{j=1}^k b_j x_j + \sum_{i < j}^k b_{ij} X_i X_j + \sum_{j=1}^k b_{jj} x_j^2$$

gdje je:

b_0 - slobodni član

$\sum_{j=1}^k b_j x_j$ - glavni efekti

$\sum_{i < j}^k b_{ij} X_i X_j$ - interakcije prvog reda

$\sum_{j=1}^k b_{jj} x_j^2$ - kvadratni članovi izrađenog matematičkog modela.

Regresijska analiza se provodi s kodiranim faktorima i koeficijenti se izračunavaju prema tom kodiranju. Matematički model sa stvarnim faktorima se prevodi iz kodiranih faktora prema izrazu:

$$X_{kod} = \frac{x_{stv} - \bar{x}}{(x_- - x_+)/2}$$

gdje je:

x_{stv} - stvarni faktor

\bar{x} - prosječna vrijednost stvarnog faktora

x_+ - gornja razina stvarnog faktora

x_- - donja razina stvarnog faktora

Dobiveni matematički model s kodnim vrijednostima je prikazan na slici 19., a navedeni izračun stvarnih faktora iz kodnih je prikazan na slici 20.

Final Equation in Terms of Coded Factors:

$$\begin{aligned} \text{Udarni rad loma (Zavar)} = & \\ & +113.52 \\ & -13.25 * A \\ & -4.03 * B \\ & +7.17 * C \\ & +14.77 * A^2 \\ & +8.93 * B^2 \\ & +9.46 * C^2 \end{aligned}$$

Slika 19. Matematički model s kodnim faktorima

Final Equation in Terms of Actual Factors:


$$\begin{aligned}
 \text{Udarni rad loma (Zavar)} = & \\
 & +665.08184 \\
 & -16.97673 * \text{udio CO2 u Ar} \\
 & -55.62088 * \text{unos topline} \\
 & -1.03142 * \text{temperatura predgrijavanja} \\
 & +0.41021 * \text{udio CO2 u Ar}^2 \\
 & +2.23350 * \text{unos topline}^2 \\
 & +7.72597\text{E-}003 * \text{temperatura predgrijavanja}^2
 \end{aligned}$$

Slika 20. Matematički model s stvarnim vrijednostima

Normalizirani papir vjerojatnosti ostataka u odnosu na vrijednosti predviđenog odziva će ukazati na problem ukoliko postoji neki obrazac razdiobe prikazanih ostataka u odnosu na vrijednosti izračunatog (predviđenog) odziva. Slika 21. prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa.


Design-Expert® Softwar
Udarni rad loma (Zavar)

Color points by value of
Udarni rad loma (Zavar)



Slika 21. Normalizirani papir vjerojatnosti

Dijagram ostataka u odnosu na redoslijed izvođenja plana pokusa provjerava postojanje sistematske pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 22. prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa. Vidljivo je da ne postoji sistematska pogreška u pozadini.



Slika 22. Slučajno rasipanje ostataka

Na slici 23. je prikazan konturni dijagram matematičkog modela ovisnosti udarnog rada loma o ulaznim veličinama.

Design-Expert® Softwar

Udarni rad loma (Zavar)

● Design Points

181.4


107.7

X1 = A: udio CO₂ u Ar

X2 = B: unos topline

Actual Factor

C: temperatura predgrija



Slika 23. Konturni dijagram za Zavar

Na konturnom dijagramu je otvorena je jedna točka kako bi se vidjelo da programski paket daje predviđanje s određenim ulaznim faktorima uz interval povjerenja i interval pretpostavki. Naime, na slici se vidi da uz udio CO₂ u Argonu od 16,31% i 11.02 KJ/cm unosa topline uz temperaturu predgrijavanja od 80 °C, udarni rad loma iznositi će gornje granice 138,396 KV(J/cm²) i donje od 106,659 KV(J/cm²) sa vjerojatnošću od 95%. Slika 24. prikazuje 3D prikaz odzivnih površina navedenog matematičkog modela.

Design-Expert® Softwar

Udarni rad loma (Zavar)

● Design points above

○ Design points below

181.4


107.7

X1 = A: udio CO₂ u Ar

X2 = B: unos topline

Actual Factor

C: temperatura predgrijz



Slika 24. 3D prikaz odzivne površine za temperaturu predgrijavanja

8.2. Primjer djelomičnog plana pokusa

Ovaj eksperiment preuzet je iz norme ISO 12845. Primjer se bavi tehnologijom oblikovanja u proizvodnji PVC pjene koja sadrži dvanaest sastavnih dijelova, odnosno čimbenika, i prolazi kroz kompleksan proizvodni proces. Broj mjernih vrijednosti na proizvodu je velik, a neki su usko međusobno povezani. Iako je poznato kako pojedini čimbenici funkcioniraju individualno, potreban je drugačiji pristup kako bi se bolje shvatilo kako funkcioniraju u cjelini te da se prouči utjecaj promjene faktora na proizvodni proces. Tome služi djelomični faktorski pokus koji će uz najmanji broj provedenih pokusa omogućiti maksimalnu količinu informacija o tome kako ulazne varijable utječu na izlazne podatke procesa odnosno ekonomičnu upotrebu laboratorijske opreme i vremena.

Iako je poznato je petnaest čimbenika koje čine formulaciju pjene što maksimizira količinu informacija za svaku formulaciju, u ovom primjeru će se analizirati tri najvažnije izlazne varijable: moment sile spajanja, omjer razvlačenja i istezljivost uz uporabu različite opreme pri fiksним uvjetima.

U pokusu se analizira devet faktora na dvije razine (tablica 12.), odnosno sastavnih tvari PVC smjese, a ostali faktori se smatraju manje utjecajnim na proces te se ponašaju kao konstante.

Tablica 12. Faktori i njihove razine

Factors					
	Name	Units	Type	Low	High
A:	CaSt		Numeric	0.2	1
B:	OPWax		Numeric	0.3	0.7
C:	AC680A		Numeric	0.2	0.6
D:	G60		Numeric	0.2	1
E:	G21		Numeric	0.1	0.7
F:	95T		Numeric	1	5
G:	K400		Numeric	4	7
H:	BIN		Numeric	1.2	1.8
J:	EPE		Numeric	0.15	0.25


Za izračun je korišten softerski program Desing Expert kako bi se skratio postupak računanja i dobio odgovarajući grafički prikaz procesa. U planu se koristi rezolucija III u šesnaest pokusa, a označava se sa 2_{III}^{9-5} . U tablici 13. vidljiva je matrica visokih i niskih razina glavnih utjecaja i izlazni podaci dobiveni u pokusu.

Tablica 13. Rezultati pokusa generirani programom Desing Expert

Select	Std	Run	Factor 1 A:CaSt	Factor 2 B:OPWax	Factor 3 C:AC680A	Factor 4 D:G60	Factor 5 E:G21	Factor 6 F:95T	Factor 7 G:K400	Factor 8 H:BIN	Factor 9 J:EPE	Response 1 Fusion torque Nm	Response 2 Hot expansion	Response 3 Elongation at b %
1		7	0.20	0.30	0.20	0.20	0.10	1.00	4.00	1.20	0.25	56	2.98	472
2		1	1.00	0.30	0.20	0.20	0.70	1.00	7.00	1.80	0.15	57.3	3.48	254
3		2	0.20	0.70	0.20	0.20	0.70	5.00	4.00	1.80	0.15	50.2	2.16	454
4		10	1.00	0.70	0.20	0.20	0.10	5.00	7.00	1.20	0.25	58	3.66	337
5		5	0.20	0.30	0.60	0.20	0.70	5.00	7.00	1.20	0.15	52.7	2.44	537
6		14	1.00	0.30	0.60	0.20	0.10	5.00	4.00	1.80	0.25	52	3.28	517
7		6	0.20	0.70	0.60	0.20	0.10	1.00	7.00	1.80	0.25	58.8	3.27	400
8		13	1.00	0.70	0.60	0.20	0.70	1.00	4.00	1.20	0.15	48.4	1.74	228
9		9	0.20	0.30	0.20	1.00	0.10	5.00	7.00	1.80	0.15	57.3	3.71	447
10		18	1.00	0.30	0.20	1.00	0.70	5.00	4.00	1.20	0.25	46.4	2.62	531
11		3	0.20	0.70	0.20	1.00	0.70	1.00	7.00	1.20	0.25	50.9	2.35	450
12		17	1.00	0.70	0.20	1.00	0.10	1.00	4.00	1.80	0.15	52.1	3.36	399
13		8	0.20	0.30	0.60	1.00	0.70	1.00	4.00	1.80	0.25	45.7	1.97	366
14		16	1.00	0.30	0.60	1.00	0.10	1.00	7.00	1.20	0.15	57.6	3.48	458
15		4	0.20	0.70	0.60	1.00	0.10	5.00	4.00	1.20	0.15	49.4	2.5	532
16		15	1.00	0.70	0.60	1.00	0.70	5.00	7.00	1.80	0.25	51.6	2.68	270
17		11	0.60	0.50	0.40	0.60	0.40	3.00	5.50	1.50	0.20	53.4	2.94	410
18		19	0.60	0.50	0.40	0.60	0.40	3.00	5.50	1.50	0.20	53.1	2.98	414
19		12	0.60	0.50	0.40	0.60	0.40	3.00	5.50	1.50	0.20	54.6	2.98	472

Analiza utjecaja na moment sile spajanja

Pomoću funkcije *Probability plot* dobivamo grafički prikaz efekata pri čemu su faktori koji leže duž linije zanemarivi dok su oni najudaljeniji utjecaji koji imaju najveću važnost. (Slika 25.)



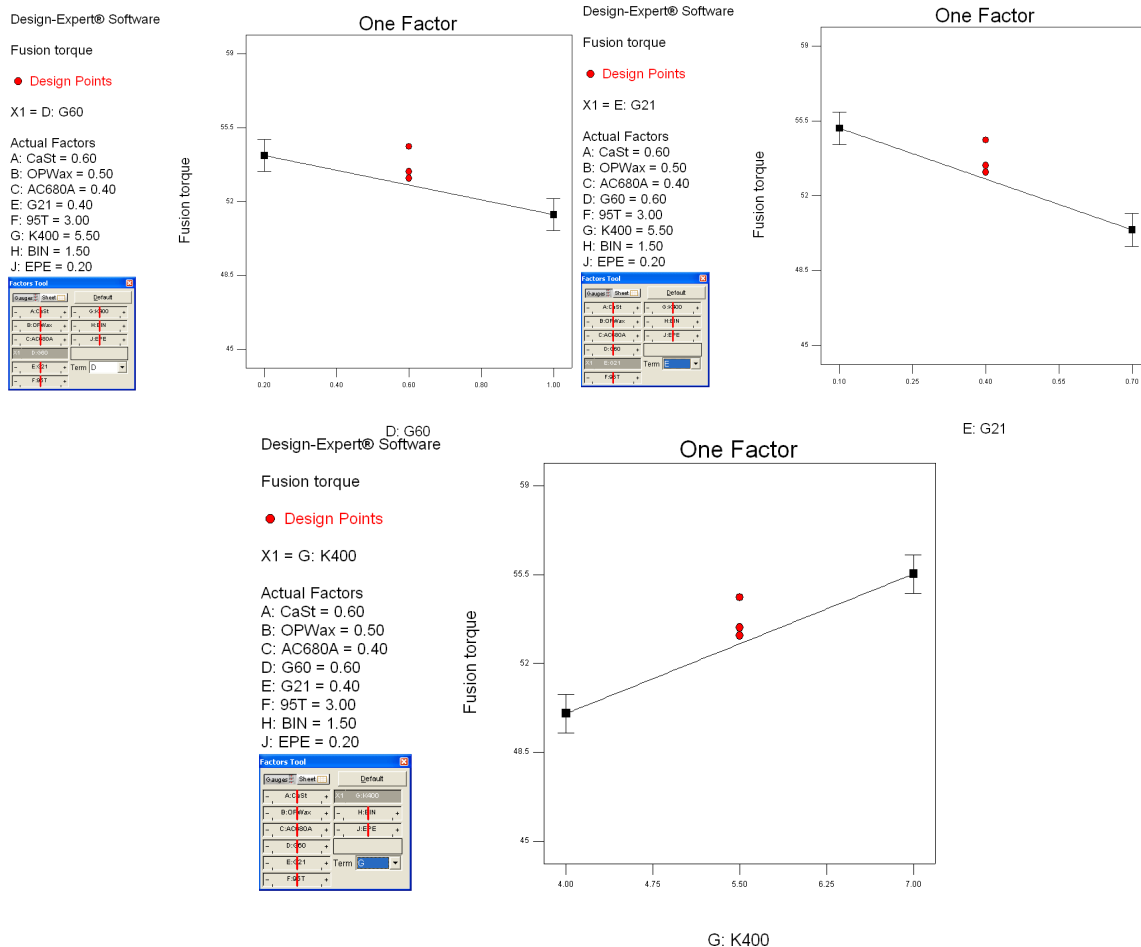
Slika 25. Djelomično normalizirani papir vjerojatnosti

Iz grafa je vidljivo da najznačajniji utjecaj na proces imaju faktori D, E, G. R-square za ovaj primjer je 89% što pokazuje da je model značajan. Sva tri glavna utjecaja su signifikantna i ako uzmemo u obzir samo njih, potrebno je te elemente staviti na odgovarajuću razinu kako bi proizvod bio ekonomičan.

Tablica 14. Rezultati analize varijance za moment sile spajanja


Response 1		Fusion torque				
ANOVA for selected factorial model						
Analysis of variance table [Partial sum of squares - Type III]						
	Sum of		Mean	F	p-value	
Source	Squares	df	Square	Value	Prob > F	
Model	242.61	3	80.87	36.88	< 0.0001	significant
D-G60	31.36	1	31.36	14.30	0.0020	
E-G21	90.25	1	90.25	41.16	< 0.0001	
G-K400	121.00	1	121.00	55.18	< 0.0001	
Curvature	2.16	1	2.16	0.99	0.3376	not significant
Residual	30.70	14	2.19			
Lack of Fit	29.44	12	2.45	3.89	0.2223	not significant
Pure Error	1.26	2	0.63			
Cor Total	275.47	18				

	Coefficient		Standard	95% CI	95% CI	
Factor	Estimate	df	Error	Low	High	VIF
Intercept	52.78	1	0.37	51.98	53.57	
D-G60	-1.40	1	0.37	-2.19	-0.61	1.00
E-G21	-2.38	1	0.37	-3.17	-1.58	1.00
G-K400	2.75	1	0.37	1.96	3.54	1.00
Center Point	0.92	1	0.93	-1.07	2.92	1.00



Slika 26. Grafički prikaz rezultata varijance za moment sile spajanja

Analiza utjecaja na omjer razvlačenja



Slika 27. Djelomično normalizirani papir vjerojatnosti

Ako promatramo rezultat pokusa na omjer razvlačenja, iz grafa je vidljivo da postoji šest najznačajnijih faktora A, B, C, E, G i H, te jedno slabo međudjelovanje AC. R-square za ovaj primjer je 99% što pokazuje da je model značajan.

Tablica 15. Rezultati analize varijance za omjer razvlačenja

Response 2		Hot expansion ratio				
ANOVA for selected factorial model						
Analysis of variance table [Partial sum of squares - Type III]						
	Sum of		Mean	F	p-value	
Source	Squares	df	Square	Value	Prob > F	
Model	5.87	7	0.84	125.05	< 0.0001	significant
A-CaSt	0.53	1	0.53	79.52	< 0.0001	
B-OPWax	0.31	1	0.31	46.79	< 0.0001	
C-AC680A	0.55	1	0.55	81.71	< 0.0001	
E-G21	2.89	1	2.89	431.24	< 0.0001	
G-K400	1.24	1	1.24	185.51	< 0.0001	
H-BIN	0.29	1	0.29	42.71	< 0.0001	
AC	0.053	1	0.053	7.89	0.0185	
Curvature	0.032	1	0.032	4.70	0.0553	not significant
Residual	0.067	10	6.702E-003			
Lack of Fit	0.066	8	8.244E-003	15.46	0.0622	not significant
Pure Error	1.067E-003	2	5.333E-004			
Cor Total	5.96	18				
	Coefficient		Standard	95% CI	95% CI	
Factor	Estimate	df	Error	Low	High	VIF
Intercept	2.86	1	0.020	2.81	2.90	
A-CaSt	0.18	1	0.020	0.14	0.23	1.00
B-OPWax	-0.14	1	0.020	-0.19	-0.094	1.00
C-AC680A	-0.19	1	0.020	-0.23	-0.14	1.00
E-G21	-0.43	1	0.020	-0.47	-0.38	1.00
G-K400	0.28	1	0.020	0.23	0.32	1.00
H-BIN	0.13	1	0.020	0.088	0.18	1.00
AC	-0.057	1	0.020	-0.10	-0.012	1.00
Center Point	0.11	1	0.052	-3.093E-003	0.23	1.00

Design-Expert® Software

Hot expansion ratio

● Design Points

■ C- 0.200

▲ C+ 0.600

X1 = A: CaSt

X2 = C: AC680A

Actual Factors

B: OPWax = 0.50

D: G60 = 0.60



E: G21 = 0.40

F: 95T = 3.00

G: K400 = 5.50

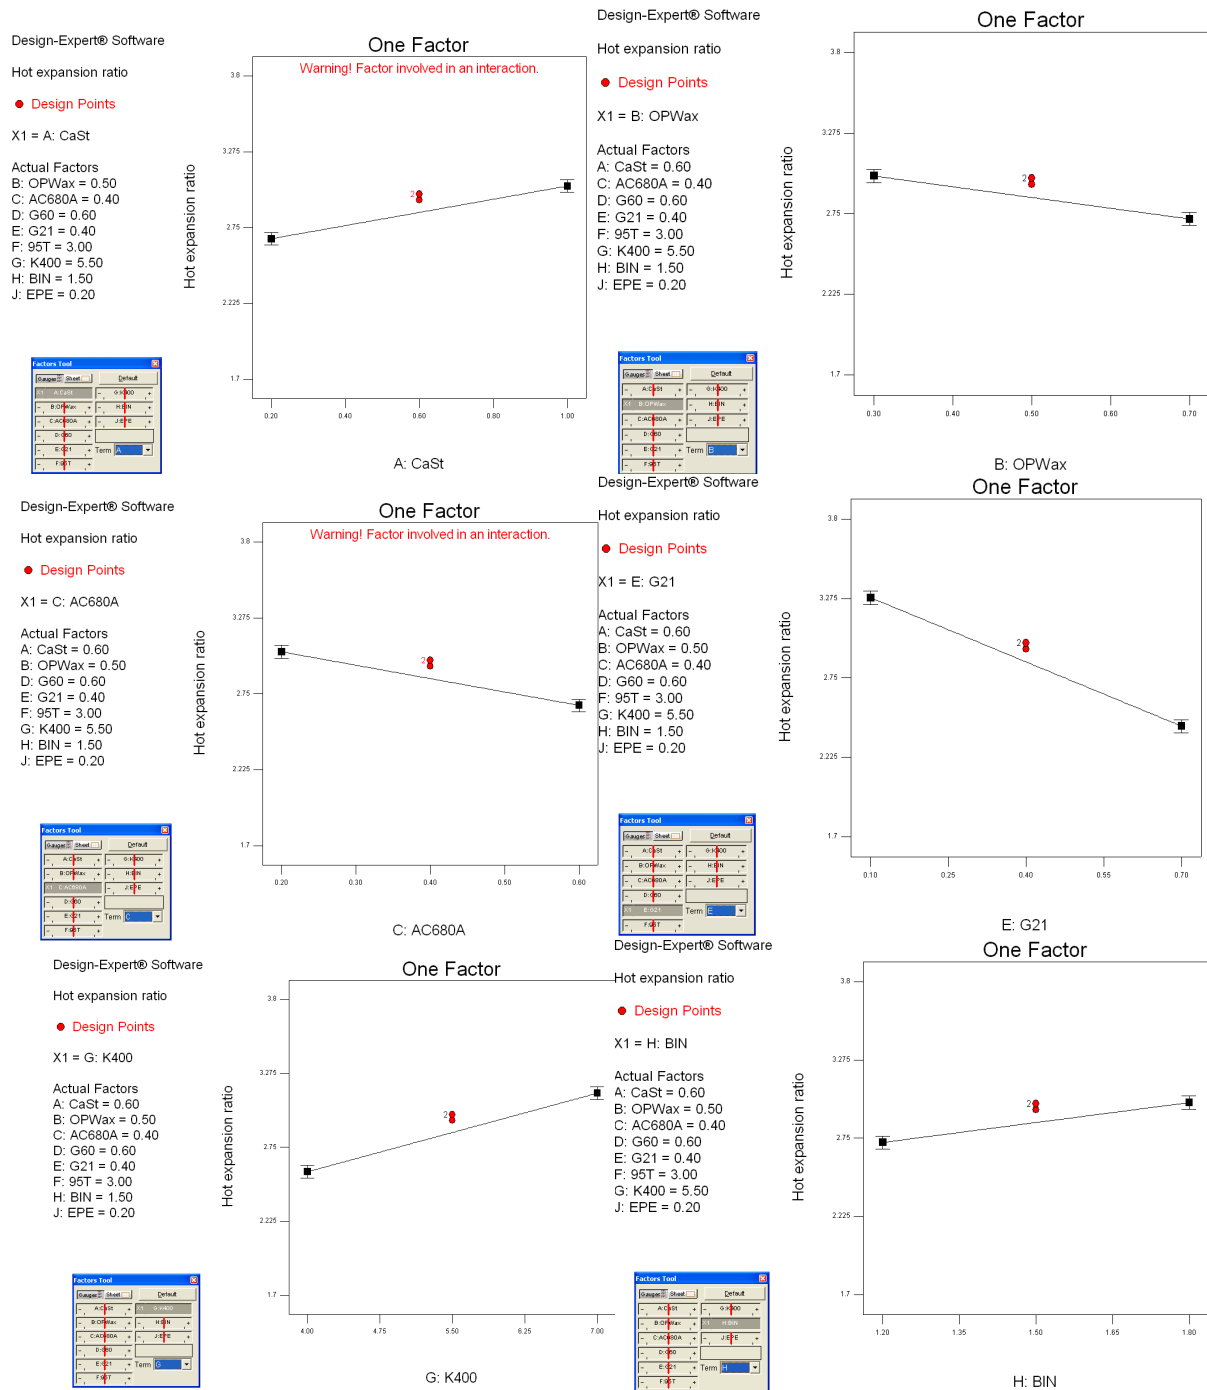
H: BIN = 1.50

J: EPE = 0.20




Slika 28. Grafički prikaz međudjelovanja faktora A i C na omjer razvlačenja

Budući da je međudjelovanje faktora AC daje vrlo slab efekt, neće se uzimati u obzir iz praktičnih razloga. Time se model neće bitno mijenjati.



Slika 29. Grafički prikaz rezultata varijance za omjer razvlačenja

Analiza utjecaja na istezljivosti



Slika 30. Djelomično normalizirani papir vjerojatnosti

Iz grafa je vidljivo da bi bilo dvanaest faktora značajnih za model uz R-square 98%. Budući da su neki faktori neobjašnjivo utjecali na model, zaključeno je da se neće uzimati u obzir. Razlog može biti premali broj repliciranja i preveliki broj koji ometa učinak faktora.

Tablica 16. Rezultati analize varijance za istezljivost

Response	3	Elongation at break				
ANOVA for selected factorial model						
Analysis of variance table [Partial sum of squares - Type III]						
	Sum of		Mean	F	p-value	
Source	Squares	df	Square	Value	Prob > F	
Model	1.518E+005	12	12649.56	22.70	0.0014	significant
A-CaSt	27556.00	1	27556.00	49.45	0.0009	
B-OPWax	16384.00	1	16384.00	29.40	0.0029	
D-G60	4032.25	1	4032.25	7.24	0.0433	
E-G21	13924.00	1	13924.00	24.99	0.0041	
F-95T	22350.25	1	22350.25	40.11	0.0014	
G-K400	7482.25	1	7482.25	13.43	0.0145	
H-BIN	11990.25	1	11990.25	21.52	0.0056	
AB	18225.00	1	18225.00	32.71	0.0023	
AD	9506.25	1	9506.25	17.06	0.0091	
AE	9216.00	1	9216.00	16.54	0.0097	
AG	8372.25	1	8372.25	15.02	0.0117	
AH	2756.25	1	2756.25	4.95	0.0767	
Curvature	667.11	1	667.11	1.20	0.3238	not significant
Residual	2786.25	5	557.25			
Lack of Fit	378.25	3	126.08	0.10	0.9500	not significant
Pure Error	2408.00	2	1204.00			
Cor Total	1.552E+005	18				

Factor	Coefficient	df	Standard	95% CI		VIF
	Estimate		Error	Low	High	
Intercept	415.75	1	5.90	400.58	430.92	
A-CaSt	-41.50	1	5.90	-56.67	-26.33	1.00
B-OPWax	-32.00	1	5.90	-47.17	-16.83	1.00
D-G60	15.87	1	5.90	0.70	31.05	1.00
E-G21	-29.50	1	5.90	-44.67	-14.33	1.00
F-95T	37.37	1	5.90	22.20	52.55	1.00
G-K400	-21.63	1	5.90	-36.80	-6.45	1.00
H-BIN	-27.38	1	5.90	-42.55	-12.20	1.00
AB	-33.75	1	5.90	-48.92	-18.58	1.00
AD	24.38	1	5.90	9.20	39.55	1.00
AE	-24.00	1	5.90	-39.17	-8.83	1.00
AG	-22.87	1	5.90	-38.05	-7.70	1.00
AH	13.13	1	5.90	-2.05	28.30	1.00
Center Point	16.25	1	14.85	-21.93	54.43	1.00

Na kraju pokusa se može zaključiti kako faktori E i G imaju najznačajniji učinak jer se pojavljuju u oba modela te imaju važnu ulogu u formiranju PVC pjene. Više faktora G i manja količina faktora E je potrebna kako bi se maksimizirao moment sile spajanja i omjer razvlačenja. Ne postoje međudjelovanja između tih faktora. Efekti ostalih faktora nisu značajni.

9. ZAKLJUČAK

Šest sigma metodologija teži postizanju efikasnosti procesa, odnosno razinu greške smanjiti na minimum i tako povećati kvalitetu samog procesa. U tom cilju smanjenja troškova i postizanja stalnog poboljšavanja procesa, razvijene su brojne metode i alati upravljanja kvalitetom. Jedna od tih metodologija je i DMAIC koja se najčešće koristi za pojedinačne projekte unaprjeđenja procesa. Trendovi unapređivanja proizvodnih sustava kao što su Šest sigma i DMAIC metoda poboljšavanja, posebno u dijelu analize i poboljšanja, intenzivno koriste statistički alat planiranje pokusa.

Upotrebom planiranja pokusa možemo znatno povećati efikasnost samog procesa eksperimentiranja i dovesti do boljih i pouzdanijih zaključaka. Planiranje pokusa je dio znanstvenog procesa, jedan od načina da saznamo kako sustav ili proces radi. Za razliku od eksperimentiranja koje podrazumijeva variranje vrijednosti jednog čimbenika dok se ostali drže na konstantnim vrijednostima, statističke metode planiranja pokusa omogućuju istovremeno variranje više čimbenika, čija naknadna analiza omogućava dobivanje podataka o njihovom utjecaju kao i utjecaj međudjelovanja čimbenika. Budući da ljudi mogu pratiti pojedinačno utjecaj samo jednog čimbenika, potrebni su računalni algoritmi kako bi se omogućila usporedba više čimbenika odjednom kao i njihova međudjelovanja.

Metode planiranja pokusa i njihova statistička obrada značajno ubrzavaju i poboljšavaju proces istraživanja i dovode do pouzdanijih zaključaka naspram drugih alata koje imamo na raspolaganju. U eksperimentalnom dijelu kroz dva različita primjera objašnjeno je kako se plan pokusa primjenjuje koristeći softverski program DesignExpert kroz čije je rezultate dana analiza i zaključak oba eksperimenta koja je pokazala kako pojedini faktori utječu na odzivne varijable.

10. POPIS SLIKA

Slika 1. DPMO	2
Slika 2. Normalna razdioba.....	3
Slika 3. Pomak procesa	4
Slika 4. DMAIC metoda poboljšavanja procesa.....	8
Slika 5. DMADV metoda poboljšavanja procesa	9
Slika 6. Metoda crne kutije	15
Slika 7. Grafički prikaz potpunog plana pokusa 2^2	19
Slika 8. Grafički prikaz potpunog plana pokusa 2^2	21
Slika 9. Odziv faktora A bez međudjelovanja faktora B	22
Slika 10. Odziv faktora A sa međudjelovanjem faktora B	22
Slika 11. Grafički prikaz potpunog plana pokusa 2^3	23
Slika 12. Grafički prikaz plana s tri čimbenika na dvije razine:	28
Slika 13. Grafički prikaz 2^{3-1} djelomičnog plana pokusa	30
Slika 14. Konceptcija robusnog dizajna.....	34
Slika 15. Grafički prikaz funkcije gubitka kvalitete	35
Slika 16. Dijagram vanjske matrice 2^2 uvjeta šumova (E) i unutarnje matrice 2^3 uvjeta procesnih parametara (X) Taguchijevog plana pokusa.....	38
Slika 17. Centralno kompozitni plan pokusa za tri faktora.....	40
Slika 18. Model	46
Slika 19. Matematički model s kodnim faktorima.....	50
Slika 20. Matematički model s stvarnim vrijednostima.....	51
Slika 21. Normalizirani papir vjerojatnosti.....	51
Slika 22. Slučajno rasipanje ostataka.....	52
Slika 23. Konturni dijagram za Zavar	53
Slika 24. 3D prikaz odzivne površine za temperaturu predgrijavanja	54
Slika 25. Djelomično normalizirani papir vjerojatnosti.....	56
Slika 26. Grafički prikaz rezultata varijance za moment sile spajanja	58
Slika 27. Djelomično normalizirani papir vjerojatnosti.....	58
Slika 28. Grafički prikaz međudjelovanja faktora A i C na omjer razvlačenja	60
Slika 29. Grafički prikaz rezultata varijance za omjer razvlačenja.....	61
Slika 30. Djelomično normalizirani papir vjerojatnosti.....	62

11. POPIS TABLICA

Tablica 1. Matrica kodiranih vrijednosti glavnih utjecaja	20
Tablica 2. Matrica kodiranih vrijednosti glavnih utjecaja za potpuni plan pokusa 2^3	24
Tablica 3. Matrica kodiranih vrijednosti glavnih utjecaja i međudjelovanja za 2^3	25
Tablica 4. Korisne rezolucije za izradu djelomičnog plana pokusa.....	28
Tablica 5. Razine čimbenika.....	29
Tablica 6. Rasponi faktora	43
Tablica 7. Faktori i njihove razine	43
Tablica 8. Stanje pokusa stohastički generirano programom Desing Expert	45
Tablica 9. Rezultati analize varijance za zavar	47
Tablica 10. Rezultati analize varijance za ZUT (model nije značajan)	47
Tablica 11. Pregled statističkih podataka modela za Zavar	49
Tablica 12. Faktori i njihove razine	55
Tablica 13. Rezultati pokusa generirani programom Desing Expert.....	56
Tablica 14. Rezultati analize varijance za moment sile spajanja	57
Tablica 15. Rezultati analize varijance za omjer razvlačenja	59
Tablica 16. Rezultati analize varijance za istezljivost.....	63

12. LITERATURA

- [1] Bass, I.: „Six sigma statistics with excel and Minitab“, McGraw Hill Professional, 2007.
- [2] Cajner, H.: „Planiranje pokusa“, Fakultet strojarstva i brodogradnje, Zagreb, predavanja, 2012.
- [3] Kolednjak, D.: „Utjecaj parametara zavarivanja na strukturu i svojstva čelika API 5L X80“, Doktorski rad, Fakultet strojarstva i brodogradnje, Zagreb, 2014.
- [4] Hinkelmann, K.: „Design and Analysis of Experiments“, 2008.
- [5] Ivić, K., Jurković, Z., Marinković, R.: „Upravljanje promjenama primjenom Taguchi metode“, 2009.
- [6] Mudronja, V.: „Kontrola kvalitete“, Fakultet strojarstva i brodogradnje, Zagreb, predavanja, 2012.
- [7] Pyzdek, T.: „Six Sigma Handbook“, 2003.
- [8] Roth, T.: „Working with the qualityTools package“, 2013.
- [9] Šibalija, V.T.: „Razvoj modela inteligentnog projektanta proizvodnih procesa na bazi Taguchi metoda“, Beograd, 2010.
- [10] Ukrainczyk, M.: „Planiranje pokusa u industriji“, Hrvatski časopis za prehrambenu tehnologiju, biotehnologiju i nutricionizam
- [11] ISO/TR 12845. Selected illustrations of fractional factorial screening experiments, 2010.
- [12] web stranica, www.wikipedia.org/wiki/Six_Sigma (03.06.2014.)
- [13] web stranica, www.webapps.r-qualitytools.org (10.05.2014.)
- [14] web stranica, www.statease.com/software.html (13.06.2012.)
- [15] web stranica, www.design-expert2.software.informer.com (13.06.2012.)
- [16] web stranica, www.issuu.com/kvaliteta.net/docs/cajner-h_babic-a_sakic-n-rad